



ACTA DE EVALUACIÓN DE LA TESIS DOCTORAL

Año académico 2016/17

DOCTORANDO: MACHADO LLERENA, OSMELL

PROGRAMA DE DOCTORADO: D332 DOCTORADO EN ELECTRÓNICA: SISTEMAS ELECTRÓNICOS AVANZADOS. SISTEMAS INTELIGENTES

DEPARTAMENTO DE: Electrónica

TITULACIÓN DE DOCTOR EN: DOCTOR/A POR LA UNIVERSIDAD DE ALCALÁ

En el día de hoy 14/07/17, reunido el tribunal de evaluación nombrado por la Comisión de Estudios Oficiales de Posgrado y Doctorado de la Universidad y constituido por los miembros que suscriben la presente Acta, el aspirante defendió su Tesis Doctoral, elaborada bajo la dirección de FRANCISCO RODRÍGUEZ SÁNCHEZ // PEDRO MARTÍN SÁNCHEZ.

Sobre el siguiente tema: *ESTRATEGIAS DE OPTIMIZACIÓN DEL CONTROL PREDICTIVO DE UN CONVERTIDOR MULTINIVEL-NPC Y SU IMPLEMENTACIÓN EN FPGA*

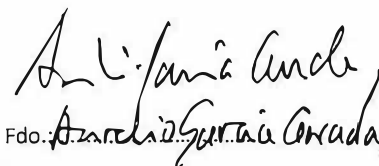
Finalizada la defensa y discusión de la tesis, el tribunal acordó otorgar la CALIFICACIÓN GLOBAL<sup>6</sup> de (no apto, aprobado, notable y sobresaliente): SOBRESALIENTE.

Alcalá de Henares, 14 de Julio de 2017

EL PRESIDENTE

  
Fdo. EMILIO BUENO

EL SECRETARIO

  
Fdo. Ana María Ancho

EL VOCAL

  
Fdo. Eric Ronnassen

Con fecha 24 de julio de 2017 la Comisión Delegada de la Comisión de Estudios Oficiales de Posgrado, a la vista de los votos emitidos de manera anónima por el tribunal que ha juzgado la tesis, resuelve:

- ☐ Conceder la Mención de "Cum Laude"  
☒ No conceder la Mención de "Cum Laude"

La Secretaria de la Comisión Delegada



FIRMA DEL ALUMNO,

OSMELL MACHADO LLERENA.

  
Fdo.

<sup>6</sup> La calificación podrá ser "no apto" "aprobado" "notable" y "sobresaliente". El tribunal podrá otorgar la mención de "cum laude" si la calificación global es de sobresaliente y se emite en tal sentido el voto secreto positivo por unanimidad.

INCIDENCIAS / OBSERVACIONES:



Universidad  
de Alcalá

COMISIÓN DE ESTUDIOS OFICIALES  
DE POSGRADO Y DOCTORADO

En aplicación del art. 14.7 del RD. 99/2011 y el art. 14 del Reglamento de Elaboración, Autorización y Defensa de la Tesis Doctoral, la Comisión Delegada de la Comisión de Estudios Oficiales de Posgrado y Doctorado, en sesión pública de fecha 24 de julio, procedió al escrutinio de los votos emitidos por los miembros del tribunal de la tesis defendida por *MACHADO LLERENA, OSMELL*, el día 14 de julio de 2017, titulada *ESTRATEGIAS DE OPTIMIZACIÓN DEL CONTROL PREDICTIVO DE UN CONVERTIDOR MULTINIVEL-NPC Y SU IMPLEMENTACIÓN EN FPGA*, para determinar si a la misma se le concede la mención "cum laude", arrojando como resultado, 3 votos en contra.

Por lo tanto, la Comisión de Estudios Oficiales de Posgrado resuelve no otorgar la Mención de "cum laude" a dicha Tesis.

Alcalá de Henares, 27 de julio de 2017  
EL PRESIDENTE DE LA COMISIÓN DE ESTUDIOS  
OFICIALES DE POSGRADO Y DOCTORADO



Firmado digitalmente por VELASCO  
PEREZ JUAN RAMON - DNI  
03087239H  
Fecha: 2017.07.30 19:07:31 +02'00'

Juan Ramón Velasco Pérez

Copia por e-mail a:

Doctorando: MACHADO LLERENA, OSMELL

Secretario del Tribunal: AURELIO GARCÍA CERRADA

Directores de Tesis: FRANCISCO RODRÍGUEZ SÁNCHEZ//PEDRO MARTÍN SÁNCHEZ



Universidad  
de Alcalá

ESCUELA DE DOCTORADO  
Servicio de Estudios Oficiales de  
Posgrado

DILIGENCIA DE DEPÓSITO DE TESIS.

Comprobado que el expediente académico de D./D<sup>a</sup> \_\_\_\_\_  
reúne los requisitos exigidos para la presentación de la Tesis, de acuerdo a la normativa vigente, y habiendo  
presentado la misma en formato: ☐ soporte electrónico ☐ impreso en papel, para el depósito de la  
misma, en el Servicio de Estudios Oficiales de Posgrado, con el nº de páginas: \_\_\_\_\_ se procede, con  
fecha de hoy a registrar el depósito de la tesis.

Alcalá de Henares a \_\_\_\_\_ de \_\_\_\_\_ de 20\_\_\_\_



Fdo. El Funcionario



UNIVERSIDAD DE ALCALÁ  
ESCUELA POLITÉCNICA SUPERIOR



Programa de Doctorado en SISTEMAS ELECTRÓNICOS  
DIGITALES AVANZADOS. SISTEMAS INTELIGENTES

ESTRATEGIAS DE OPTIMIZACIÓN DEL  
CONTROL PREDICTIVO DE UN  
CONVERTIDOR MULTINIVEL-NPC Y SU  
IMPLEMENTACIÓN EN FPGA

2017

Autor:	OSMELL MACHADO LLERENA
Director:	Dr. Francisco Javier Rodríguez Sánchez
Codirector:	Dr. Pedro Martín Sánchez



Universidad  
de Alcalá

DEPARTAMENTO DE ELECTRÓNICA  
Edificio Politécnico  
Campus Universitario s/n  
28805 Alcalá de Henares (Madrid)  
Teléfono: 91 885 65 40  
Fax: 91 885 65 91  
eldep@depeca.uah.es

Dr. Sira Elena Palazuelos Cagigas, Directora del Departamento de Electrónica de la Universidad de Alcalá,

**INFORMA:**

Que la Tesis Doctoral titulada **“Estrategias de Optimización del control predictivo de un convertidor Multinivel NPC y su implementación en FPGA”** presentada por D. Osmell Machado Llerena, y dirigida por los doctores D. Francisco Javier Rodríguez Sánchez y D. Pedro Martín Sánchez, cumple con todos los requisitos científicos y metodológicos, para ser defendida ante un Tribunal.

Alcalá de Henares, 21 de Abril de 2017



Fdo. Sira Elena Palazuelos Cagigas

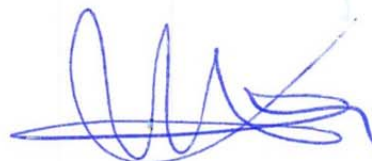
Dr. Francisco Javier Rodríguez Sánchez, Catedrático de la Universidad Alcalá, y  
Dr. Pedro Martín Sánchez, Profesor Titular de la Universidad de Alcalá

**INFORMAN:** Que la Tesis Doctoral titulada **“Estrategias de Optimización del control predictivo de un convertidor Multinivel NPC y su implementación en FPGA”** presentada por D. Osmell Machado Llerena, y realizada bajo la dirección de los doctores D. Francisco Javier Rodríguez Sánchez y D. Pedro Martín Sánchez, dentro del campo del diseño e implementación de controladores para convertidores de potencia, reúne los méritos de calidad y originalidad para optar al Grado de Doctor.

Alcalá de Henares, 21 de Abril de 2017



Fdo. Fco Javier Rodríguez Sánchez



Fdo. Pedro Martín Sánchez

# RESUMEN

Los convertidores de potencia multinivel representan una alternativa ampliamente utilizada en la gestión del flujo de energía eléctrica en sistemas de alta potencia y alta o media tensión, como puedan ser sistemas de generación de energía eólica o, en general, sistemas de generación, transmisión y distribución de energía para aplicaciones industriales. El control de este tipo de convertidores puede abordarse desde distintas estrategias, como las técnicas de Modulación de Espacios Vectoriales (SVM), la Eliminación Selectiva de Armónicos (SHE), por nombrar algunas. Por otro lado, las técnicas de Control Predictivo basado en el Modelo (MPC) han adquirido una gran relevancia en el ámbito del control de convertidores y máquinas eléctricas, debido a su precisión, rápida respuesta dinámica y la posibilidad de establecer varios objetivos de control simultáneos. La idea básica consiste en predecir el comportamiento del convertidor, utilizando un modelo discreto o descripción matemática del mismo. Por contra, estas técnicas implican una gran carga computacional, debido a que, en cada periodo de muestreo, debe optimizarse una función de coste, mediante la exploración de cada uno de los posibles estados de conmutación del convertidor. El Control Predictivo sobre un Conjunto Finito de Estados (FCS-MPC) supone un caso particular de MPC, donde el algoritmo solo se aplica a un número finito de estados de conmutación del convertidor. Posteriormente, el convertidor es configurado en aquel estado de conmutación óptimo que minimice cierta función de coste y ello, durante cada intervalo de muestreo. Para establecer la importancia de una variable respecto a otras, se incluye un factor de peso para cada uno de los términos de la función de coste. Ajustar los valores óptimos de estos factores de peso, es una etapa crucial en la especificación del algoritmo FCS-MPC, y resulta una difícil tarea, habitualmente resuelta mediante la técnica de ensayo-error. Por ello, en la mayoría de trabajos publicados en este ámbito de investigación, una vez se determinan los factores de peso, estos permanecen siempre constantes. En esta tesis, se propone un proceso general automático de ajuste de estos factores de peso. Para demostrar la viabilidad del método propuesto, se ha aplicado al caso del control FCS-MPC de un convertidor multinivel de voltaje de Punto Neutro Fijo de Tres Niveles (3L-NPC). Se han estudiado diferentes estrategias para realizar este proceso, y finalmente, se ha considerado una solución basada en Redes Neuronales Artificiales (ANN), como la mejor opción para implementar una novedosa estrategia que se ha venido en denominar: Modelo de Control Predictivo Adaptativo (A-MPC) como una versión optimizada del MPC tradicional. La función de coste incluye el error de seguimiento de las corrientes de red, la frecuencia de conmutación de los transistores IGBT, y el desequilibrio de las tensiones del Bus-DC. Consideradas como figuras de mérito, el error de las corrientes generadas, la distorsión armónica total (THD), la frecuencia media de conmutación y el desequilibrio del Bus-DC, junto con las referencias de potencia activa y reactiva, son las entradas de la red neuronal, cuyas salidas serán los factores de peso óptimos. Para reducir la carga computacional, el algoritmo trabaja usando una transformación a componentes alfa-beta de las corrientes y tensiones. Además, en la tesis se propone una metodología de implementación sobre FPGA del algoritmo de control propuesto. Por último, para evaluar las prestaciones del método de ajuste propuesto, se han realizado numerosas simulaciones y se han llevado a cabo experimentos sobre una plataforma de procesamiento conectada a un convertidor multinivel ubicado en el laboratorio de investigación del grupo GEISER.

# SUMMARY

Multilevel converters are well-established alternative used in high-power and high or medium voltage systems as wind energy conversion, generation, transmission and distribution of energy to industrial applications. Several control strategies have been developed for these converters as Space Vector Modulation (SVM) or Selective Harmonic Elimination (SHE) to name the most commonly used. However, Model Predictive Control (MPC) techniques are generating considerable interest to implement different controllers for multilevel converters, due to its accuracy, fast dynamic response and multi-target simultaneous control. The basic idea of this concept is to predict the future behavior of the converter based on its discrete model or mathematical descriptions of the system. Against, the major drawback of this technique is the high computational load required, because the model is repetitive evaluated at each sampling time for each switching state. Finite Control Set Model Predictive Control (FCS-MPC) has been developed as a particular case of MPC where the algorithm is only applied for a finite number of switching states, reducing the computational burden. Then, the controller configures the converter with the optimal switching state that minimizes a given cost function over a sampling interval. In order to establish the importance of one controlled target in relation to the others, a weighting factor is included for each term in the cost function. Adjusting the optimal values of these weighting factors is a crucial stage in the specification of a FCS-MPC and it is a difficult challenge too. Due to this, in all works currently presented, once the weighting factors have been determined, they remain unchanged. In this thesis, a FCS-MPC has been applied for a Three-Level Neutral Point Clamped (3L-NPC) voltage source converter, including an automatic tuning process of the weighting factors. Different strategies have been studied, and finally, an artificial neural network-based approach has been considered as the better solution to implement a novel controller strategy: Adaptive Model Predictive Control (A-MPC) as an optimized version of a traditional MPC. The cost function includes predictions of the grid currents, the switching frequency of the Insulated Gate Bipolar Transistors (IGBT) and the balance of the DC-link bus voltages. Merit figures such as the current tracking error, Total Harmonic Distortion (THD), average switching frequency and DC-link voltage balancing along with the active and reactive power references, are the inputs of the Artificial Neural Network (ANN) whose outputs constitute the weighting factors. In order to reduce the computational burden, alpha-beta components transformation and a FPGA-based implementation have been used. Finally, in order to evaluate the proposed method, numerous simulations and experiments have been carried out on a platform located in the research laboratory of the GEISER group.

# AGRADECIMIENTOS

El camino para llevar este estudio ha sido difícil y largo. Tanto en el ámbito personal, como en el profesional o específico de este mismo, muchas veces se presentaron obstáculos que provocaron retrasos, desilusiones o reveses, pero al tratarse de una tarea que me ha llevado a cabo tantos años, hubiera sido imposible que no se produjeran. Sin embargo, en cada uno de ellos tuve el apoyo incondicional de la gente que me rodeaba, aportándome ideas para solventar los problemas, mejoras para mejorar lo que me parecía inmejorable, o simplemente brindándome un apoyo moral y personal, en ocasiones, más necesario. He de agradecer también las críticas que haya podido recibir, porque son el único camino hacia la mejora y el deseo de la perfección a la que todo ingeniero debería aspirar. Gracias a todos ello, he podido llevar a cabo esta tarea, sintiéndome realizado personalmente al considerar que he aportado un grano de arena más, a la playa que conforma el conocimiento universal. Por todo ello, agradezco a mis directores de tesis Francisco Javier Sánchez y Pedro Martín por el interés mostrado siempre hacia mi persona, por haberme dado tantas oportunidades, y por haberme guiado por el camino de la enseñanza tan magistralmente. A Emilio Bueno por su valioso tiempo resolviendo siempre mis dudas, y a todos mis compañeros del grupo GEISER y del Departamento de Electrónica de la Universidad de Alcalá. Finalmente, quiero agradecer a mi querida esposa y familia, por su apoyo personal e incondicional y por haber creído en mí para conseguir mis objetivos.





# LISTA DE ACRÓNIMOS Y DEFINICIONES

ACRÓNIMO	DEFINICIÓN
<b>3L-NPC</b>	Three Level Neutral Point Clamped Converter (Convertidor de Tres Niveles con Punto Neutro Acoplado).
<b>AC</b>	Alternating Current (Corriente Alterna).
<b>A-MPC</b>	Adaptive Model Predictive Control (Modelo de Control Predictivo Adaptativo).
<b>ANN</b>	Artificial Neural Network (Red Neuronal Artificial).
<b>Bus-DC</b>	Bus Direct Current (Bus de Corriente Continua).
<b>C.C.</b>	Corto Circuito
<b>DC</b>	Direct Current (Corriente Continua).
<b>DSOGI-QSG</b>	Dual Second Order Generalized Integrator – Quadrature Signal Generator (Integrador Dual Generalizado de Segundo Orden – Generador de Señal en Cuadratura).
<b>DSP</b>	Digital Signal Processor (Procesador Digital de Señales).
<b>DPC</b>	Direct Power Control (Control Directo de Potencia)
<b>EMPC</b>	Explicit Model Predictive Control (Modelo de Control Predictivo Explícito)
<b>FCS-MPC</b>	Finite Control Set - Model Predictive Control (Modelo de Control Predictivo para un Conjunto Finito).
<b>FF-ANN</b>	Feed-Forward Artificial Neural Network (Red Neuronal Artificial de Propagación Hacia Adelante)
<b>FPGA</b>	Field Programmable Gate Array (Bloque Programable de Secuencias de Puertas).
<b>GPC</b>	Generalized Predictive Control (Control Predictivo Generalizado)
<b>GPU</b>	Graphic Processor Unit (Unidad Gráfica de Proceso)
<b>HCC</b>	Hysteresis Current Control (Control de Corriente por Histéresis)
<b>IGBT</b>	Isulated Gate Bipolar Transistor (Transistor Bipolar de Puerta Aislada).
<b>LMA</b>	Levenberg-Marquardt Algorithm (Algoritmo Levenberg-Marquardt).
<b>MAC</b>	Multiply-ACcumulate operations (Operaciones de multiplicación y suma).

ACRÓNIMO	DEFINICIÓN
<b>MPC</b>	Model Predictive Control (Modelo de Control Predictivo).
<b>MSE</b>	Mean Square Error (Error Cuadrático Medio).
<b>PLL</b>	Phase-Locked Loop (Lazo de Seguimiento de Fase).
<b>PWM</b>	Pulse Width Modulation (Modulación por Amplitud de Pulsos).
<b>SHE</b>	Selective Harmonic Elimination (Eliminación Selectiva de Armónicos).
<b>SRF - PLL</b>	Synchronous Reference Frame – Phase-Locked Loop (Lazo de Seguimiento de Fase con Trama de Referencia Síncrona).
<b>SVM</b>	Space Vector Modulation (Modulación por Espacio de Vectores)
<b>THD</b>	Total Harmonic Distortion (Distorsión Armónica Total).
<b>VHDL</b>	VHSIC Hardware Description Language (Lenguaje de Descripción Hardware para Circuitos Integrados de Muy Alta Velocidad).
<b>VSI</b>	Voltage Source Inverter (Fuente de Voltaje Inversora)
<b>VCO</b>	Voltage-controlled Oscillator (Oscilador controlado por tensión).
<b>XSG</b>	Xilinx System Generator (Herramienta de diseño de la familia Xilinx).

# ÍNDICE DE CONTENIDO

RESUMEN.....	IV
SUMMARY .....	V
AGRADECIMIENTOS.....	VI
LISTA DE ACRÓNIMOS Y DEFINICIONES.....	VIII
CAPÍTULO 1. INTRODUCCIÓN .....	1
1.1 Ubicación de la temática de la tesis doctoral .....	1
1.2 Revisión de Conocimientos.....	4
1.3 Alternativas Tecnológicas para Implementar el Algoritmo de Control.....	15
1.4 Alternativas para el Desarrollo del Sistema Adaptativo .....	17
1.5 Objetivos de la tesis doctoral .....	23
1.6 Organización del Documento .....	24
CAPÍTULO 2. Control Predictivo en un convertidor 3L-NPC .....	26
2.1 Introducción.....	26
2.2 Fundamentos Teóricos.....	27
2.2.1 Modelo del Inversor 3L-NPC.....	27
2.2.2 Control de las Señales de Activación de los IGBT.....	31
2.2.3 Transformación al Plano $\alpha\beta$ .....	33
2.2.4 Modelo Predictivo de la Corriente de Salida .....	36
2.2.5 Modelo Predictivo de la tensión de Red.....	39
2.2.6 Función de coste.....	40
2.2.7 Generación de la Corriente de Referencia.....	41
2.2.8 Modelo Predictivo del Desequilibrio del Bus-DC.....	49
2.2.9 Modelo Predictivo de la Frecuencia de Conmutación de los IGBT .....	53
2.3 Modelo Completo del Algoritmo de Control Predictivo.....	55
2.4 Estudio de la sensibilidad del controlador ante variaciones de distintos parámetros.....	61

2.4.1	Resistencia e inductancia del filtro de acoplo de red: $R$ y $L$ .....	62
2.4.2	Período de muestreo: $T_s$ .....	68
2.4.3	Tensión del bus-DC .....	71
2.4.4	Tensión de red .....	74
2.5	Tiempo de respuesta y respuesta en frecuencia del Algoritmo MPC .....	79
2.5.1	Tiempo de respuesta del algoritmo MPC.....	79
2.5.2	Respuesta en frecuencia .....	84
2.6	Conclusiones .....	89
CAPÍTULO 3. PROPUESTA DE Algoritmo de Control Predictivo Adaptativo O A-MPC		92
3.1	Índices de calidad del sistema .....	92
3.1.1	Error medio de tracking.....	93
3.1.2	Distorsión armónica total media.....	94
3.1.3	Desequilibrio medio del Bus-DC .....	95
3.1.4	Frecuencia media de conmutación de los IGBT .....	96
3.2	Modelo propuesto: Algoritmo de Control Predictivo Adaptativo o A-MPC. ....	97
3.2.1	Modelo del comportamiento del controlador .....	98
3.3	Obtención del espacio de observaciones.....	100
3.3.1	Márgenes de operación en potencia del inversor .....	100
3.3.2	Márgenes de variación de $\lambda_{DC}$ y $\lambda_{SW}$ .....	102
3.3.3	Obtención de índices de calidad .....	118
3.4	Posibles soluciones para diseñar la función de adaptabilidad .....	121
3.4.1	Regresión lineal múltiple .....	121
3.4.2	Redes neuronales artificiales .....	124
3.4.3	Lógica difusa .....	134
3.5	Selección del método para ajuste del controlador A-MPC.....	136
3.6	Conclusiones.....	137
CAPÍTULO 4. PROPUESTA DE IMPLEMENTACIÓN DE LA ESTRATEGIA DE OPTIMIZACIÓN		139

4.1	Modelo genérico de red neuronal Perceptrón Multicapa.....	140
4.1.1	Modelo de perceptrón o neurona artificial.....	141
4.1.2	Entrenamiento de un Perceptrón Multicapa.....	142
4.1.3	Problemas asociados.....	145
4.2	Diseño y entrenamiento de la red neuronal para el caso de estudio .....	146
4.2.1	Creación de la red neuronal.....	147
4.2.2	Entrenamiento de la red neuronal.....	153
4.2.3	Simulación del funcionamiento de la red neuronal .....	156
4.3	Conclusiones.....	157
CAPÍTULO 5. RESULTADOS EXPERIMENTALES .....		159
5.1	Aplicación del Control Predictivo Adaptativo.....	159
5.2	Resultados de la implementación de la FF-ANN .....	159
5.2.1	Diseño del bloque ANN.....	160
5.2.2	Implementación de la función Tangente-Sigmoidal .....	164
5.2.3	Implementación de una neurona de la capa oculta .....	167
5.2.4	Implementación de una neurona de la capa de salida.....	168
5.3	Resultado de la implementación de la FF-ANN .....	170
5.3.1	Comparativa entre simulación e implementación .....	171
5.3.2	Recursos consumidos y camino crítico.....	172
5.4	Configuración experimental.....	175
5.5	Introducción de potencia reactiva.....	179
5.6	Reducción de potencia.....	187
5.7	Funcionamiento continuo con cambios de referencias de potencia.....	190
5.8	Cambio de referencia de la frecuencia de conmutación .....	193
5.9	Cambio de referencia del desequilibrio del Bus-DC.....	196
CAPÍTULO 6. CONCLUSIONES FINALES .....		201
6.1	Trabajos futuros .....	204
6.2	Contribuciones y Publicaciones Asociadas.....	205

APÉNDICE I .....	207
Creación e inicialización de una red neuronal Perceptrón Multicapa en MATLAB.	207
Entrenamiento de Redes Neuronales utilizando MATLAB .....	207
Simulación de las redes FF-ANN desde MATLAB .....	209
ÍNDICE DE FIGURAS.....	211
ÍNDICE DE TABLAS.....	218





# **CAPÍTULO 1. INTRODUCCIÓN**

## **1.1 Ubicación de la temática de la tesis doctoral**

Las energías renovables constituyen la única alternativa energética viable a medio y largo plazo para atender al progresivo incremento de la demanda mundial y responder a los desafíos del cambio climático, por lo que se hace necesario continuar investigando en el diseño y desarrollo de nuevos métodos que permitan conseguir un mayor rendimiento, mejores prestaciones y un menor coste en la generación de energía. Dentro del amplio abanico de tecnologías implicadas en las energías renovables, el sector de la energía eólica es una industria que se presenta como una alternativa de las más competitivas en precio frente a la generación tradicional fósil o nuclear. No obstante, obtener energía del viento y suministrarla a la red eléctrica de una manera adecuada y controlada, no es un proceso trivial, y es necesario emplear técnicas adecuadas para el control de magnitudes como tensiones, frecuencia, potencias o corrientes.

De igual manera, muchos otros métodos de generación de energía eléctrica a partir de fuentes renovables, se basan en un elemento principal capaz de transformar la energía mecánica, ya sea del movimiento del viento, agua, vapor, olas, etc. en energía eléctrica. Sin embargo, dicha energía no puede ser inyectada directamente en la red en forma de potencia útil para el consumo o abastecimiento energético, debido a que su frecuencia y amplitud son fuertemente dependientes del movimiento mecánico. Para solventar esta incompatibilidad, se emplean convertidores de potencia capaces de acondicionar la energía creada y adecuarla para ser transmitida a la red eléctrica. Para cumplir con las especificaciones de conexión con la red eléctrica, los convertidores deben disponer de varios lazos de control que, en última instancia, se traducen en una señal de actuación generalmente basada en técnicas de modulación de pulsos en anchura. Alternativamente, gracias al continuo crecimiento de la capacidad de cómputo y frecuencia de trabajo de los sistemas digitales, es factible el empleo de controladores que, a partir de un modelo de la planta, sean capaces de generar directamente la actuación necesaria para alcanzar las especificaciones de funcionamiento, evaluando previamente el espacio discreto de posibles actuaciones y eligiendo la mejor alternativa. Es el caso del control predictivo.

El trabajo descrito en esta tesis, se centra en la optimización y mejora del control de un convertidor de 3 niveles mediante técnicas de Control Predictivo o MPC (*Model Predictive Control*). Estas técnicas han mostrado ser eficaces y a la vez relativamente sencillas, para generar y controlar corrientes trifásicas a partir de tensión continua aplicada a la entrada de un inversor multinivel. El Control Predictivo se basa, en esencia, en describir el sistema mediante un modelo matemático, que posteriormente es usado para poder predecir el comportamiento del mismo. De esta forma, el controlador puede predecir el futuro estado de funcionamiento del sistema para cada posible actuación, y así elegir aquella que minimice cierto índice de comportamiento que tenga en cuenta los errores de seguimiento de las consignas u otros objetivos de control.

De este enfoque de control, resultan algoritmos fácilmente implementables en sistemas basados en FPGA (*Field Programmable Gate Array*), capaces de trabajar con señales digitales, con gran capacidad de cómputo y a alta velocidad de proceso, sin necesidad de depender de componentes electrónicos analógicos costosos y de difícil mantenimiento, como los usados en el caso tradicional de actuación por modulaciones lineales.

Como en todos los sistemas de control, aunque con más incidencia en el Control Predictivo, el modelo de la planta y por ello, el controlador diseñado, se ven afectados por las variaciones de los parámetros del sistema bajo control y por las incertidumbres de modelado. Para el caso de control de un inversor conectado a la red, además de las variaciones de parámetros del sistema como puedan ser la inductancia del filtro de conexión o la resistencia de línea de la red (poco controlables por otro lado), debe tenerse presente que el ajuste del controlador se hace para cierto tipo de consignas, por lo que, si esta cambia, la respuesta puede no cumplir las especificaciones de diseño. Por ello, también se debe tener en cuenta el tipo de consignas de potencia que pueda recibir el convertidor.

Para intentar solucionar estos problemas, en este trabajo de investigación, se propone un algoritmo de Control Predictivo con capacidad de adaptación ante estos cambios, de tal manera que el sistema tenga cierto grado de inmunidad ante variaciones de sus parámetros. Se pretende que el sistema sea robusto, y que pueda trabajar siempre en el estado en el cual se obtengan los mejores resultados, definidos como aquellos que optimizan cierta función de coste. La mayoría de controladores se diseñan para unas condiciones muy concretas de funcionamiento, es decir, para determinadas consignas

de potencia activa y reactiva, asumiendo un modelo de la planta de parámetros conocidos y prescindiendo de la incertidumbre de modelado. Incluso así, dicho diseño puede requerir de reiteradas simulaciones, con su correspondiente análisis de resultados para obtener el controlador final. Con las propuestas realizadas en esta tesis, se pretende, a partir de una estrategia de Control Predictivo Adaptativo, a la que se denominará A-MPC, conseguir un controlador capaz de responder óptimamente ante los cambios de consigna de potencia, tanto activa como reactiva, minimizando una función de coste que permitirá, a su vez, conseguir varios objetivos de control simultáneamente. En definitiva, el objetivo básico es que el controlador predictivo sea capaz de responder adecuadamente en un margen amplio de consignas y posibles variaciones de parámetros.

Aunque la metodología propuesta de ajuste del controlador es generalizable, el trabajo se ha realizado para un modelo concreto de convertidor, en este caso para un convertidor de 3 niveles con punto neutro anclado, más conocido por su terminología inglesa como *Three Level-Neutral Point Clamped* (3L-NPC). La topología de estos convertidores, se basa en la unión de un bloque rectificador y uno inversor mediante un bus intermedio de corriente continua formado por dos condensadores, siendo su punto intermedio el punto neutro de referencia. El controlador predictivo A-MPC se aplicará solamente en el inversor, ya que es este el que está conectado a la red y quien genera las corrientes de salida, asumiéndose que existe un control adecuado para la etapa de rectificación.

El A-MPC deberá diseñarse para optimizar una función de coste en la que se incluirán la desviación de corriente que se produce respecto a la referencia o consigna, la distorsión armónica o THD (*Total Harmonic Distortion*), el desequilibrio de la tensión del Bus-DC y la frecuencia de conmutación de los transistores de conmutación del convertidor o IGBT . Aunque el controlador se diseñe para un tipo concreto de convertidor, el método y procedimiento aquí expuesto, podría ser implementado y exportado en otros sistemas y modelos, extrapolando los conceptos a los nuevos parámetros y valores.

En una primera fase, se estudiarán las diferentes alternativas de control descritas en la literatura científica, para continuar con las propuestas de la tesis doctoral, que incluirán un nuevo esquema de control predictivo adaptativo, así como un método de implementación sistemático de este controlador en hardware de procesamiento

específico (FPGA), siguiendo ciertas pautas para una codificación optimizada en VHDL.

Esta tesis se ha desarrollado dentro del grupo GEISER de la Universidad de Alcalá y, en concreto, dentro de los proyectos de investigación:

- ENE2014-57760-C2-2-R: “Convertidores de Potencia para Optimizar la Operación de Sistemas Híbridos HVDC-VSC Multiterminal/HVAC”, financiado por el Ministerio de Economía y Competitividad.
- ENE2011-28527-C04-02: “Aplicaciones de los convertidores en fuente de tensión HDVC en los sistemas eléctricos de potencia con especial atención a la operación multiterminal”, financiado por el Ministerio de Ciencia e Innovación.

## 1.2 Revisión de Conocimientos

Los convertidores multinivel de alta potencia son utilizados ampliamente en el ámbito de la generación y transporte de energía eléctrica para aplicaciones industriales, a fin de realizar conversiones de energía DC-AC, compensación de potencia reactiva o conversión de energía eólica, etc. (1) (2). Debido, entre otras razones, al aumento de la demanda eléctrica mundial, cada vez más se exige un aumento de las capacidades de los convertidores, que deben trabajar con tensiones altas para alcanzar la potencia demandada. En redes de baja tensión (tensiones inferiores a 1000V, comúnmente 110V, 220V o 440V), normalmente se usan convertidores de 2 niveles. En cambio, para redes de media y alta tensión (por encima de los 1000V), predominan los convertidores de 3 niveles. Dentro de los convertidores de 3 niveles, existen diferentes topologías, cada una de ellas adaptadas a un tipo específico de función (3). Para el caso concreto de este trabajo, se ha usado la topología de un convertidor de 3 niveles conocida como *Neutral Point Clamped*, o NPC, que cuenta con más de 25 años de utilización en sistemas de generación de energía.

En la conexión a red de sistemas de generación, pueden considerarse dos partes fundamentales. La primera de ellas es una etapa rectificadora, capaz de convertir la energía alterna no controlada de un generador AC, en una tensión continua estable de valor conocido, conformando un bus de corriente continua que actúa de suministrador de potencia al siguiente bloque. Este bus es denominado comúnmente Bus-DC o *Direct Current-Link* (DC-Link) en inglés. Para lograr la tensión continua final, se utilizan condensadores que estabilizan las tensiones de salida de la etapa rectificadora. A continuación, mediante una etapa inversora o VSI (*Voltage Source Inverter*) se

consigue una salida trifásica alterna con frecuencia y amplitud adecuadas para la conexión a la red eléctrica, usando la tensión continua aportada por el Bus-DC. Así mismo, la utilización de un inversor permite controlar el desfase de las corrientes respecto a las tensiones comunes de la red, a fin de permitir el control de la potencia activa y potencia reactiva que se suministra. Esto permite establecer qué potencia útil se suministra a la red, sin cambiar las amplitudes y frecuencias de las señales, y por tanto manteniendo sus valores eficaces.

En la Figura 1 se muestra el esquema general de bloques anteriormente comentados e implicados en la generación de energía eléctrica, utilizando en este caso un convertidor de 3 niveles NPC.

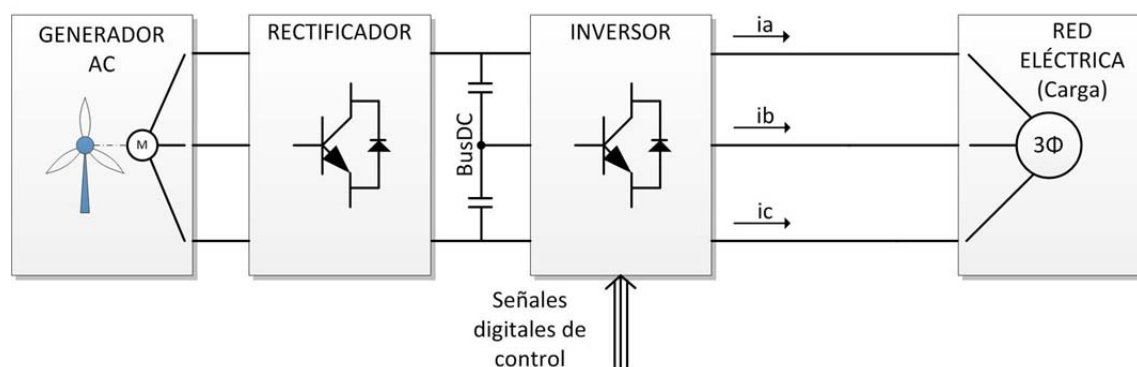


Figura 1. Diagrama genérico de bloques que intervienen en la generación de energía eléctrica a partir de un generador de corriente AC.

En sistemas de generación de energía eólica, son comúnmente utilizados los denominados convertidores de voltaje multinivel “*back-to-back*” que poseen la estructura antes descrita, y que tienen un carácter reversible, capaces de arrancar el generador eólico funcionando como un motor con potencia procedente de la red eléctrica, para que, una vez este esté funcionando y sea capaz de generar energía por sí mismo, se invierta el sentido del flujo de potencia hacia la red. En su mayoría, tanto los rectificadores como los inversores de potencia incluidos en los sistemas *back-to-back*, están basados en elementos semiconductores de conmutación controlados por señales digitales, como es el caso de los transistores IGBT (*Insulated Gate Bipolar Transistor*). Estos dispositivos electrónicos funcionan como interruptores, casi siempre conectando las líneas de salida a alguno de los niveles de tensión propios del convertidor, y haciéndolo a frecuencias relativamente altas, del orden de kilohercios. Como resultado de estas conmutaciones, en cada línea de salida se conforman señales con los diferentes niveles de tensión del convertidor.

No es difícil de entender, que la etapa inversora tiene una gran importancia en el proceso, y que de su rendimiento dependerá en gran medida el buen funcionamiento de todo el sistema. Es por ello por lo que el objetivo principal de esta tesis, gira en torno a este bloque, asumiendo, como ya se ha mencionado, que existe una etapa rectificadora previa capaz de aportar la tensión DC suficiente y necesaria.

Teniendo en cuenta todo lo anterior, el paso final en el proceso de la conversión de energía, consiste en la generación de las corrientes de salida del inversor hacia la red eléctrica, para asegurar el seguimiento de las consignas de potencia. Esta tarea corresponde al controlador y a la subsiguiente interfaz de actuación.

Así como el diseño y la topología del convertidor es muy dependiente del tipo de aplicación a la que se destine, un mismo convertidor puede ser controlado por diferentes métodos o algoritmos de control, por lo que su diseño es un tema abierto y susceptible de ser estudiado y mejorado.

En esencia, la actuación del control se realiza mediante las señales digitales de excitación de los IGBT que lo componen, concretamente mediante una modulación por anchura de pulsos o *Pulse Width Modulation* (PWM). Una de las diferencias existentes entre las distintas técnicas de control, radica en la manera de generar estas señales PWM.

La Figura 2 muestra un ejemplo de las formas de ondas de las señales implicadas en la generación de las corrientes para el caso de un convertidor de tres niveles, para una de las fases de red. En ella se puede ver cómo las tensiones de salida del inversor (como en este caso  $V_{A0}$ ) conmutan entre los diferentes niveles de tensión del inversor, en este caso 3, para posteriormente, previo filtrado, generar las corrientes de frecuencia fundamental de 50Hz  $i_a$ ,  $i_b$  e  $i_c$ .

En la bibliografía y praxis de control de convertidores, existen multitud de técnicas para desarrollar un controlador de corriente, dependiendo de las necesidades de cada sistema y/o aplicación.

Históricamente, se han utilizado varias técnicas de control para los convertidores multinivel. Las basadas en modulación lineal de vectores o *Space Vector Modulator* (SVM), y las de modulación con eliminación selectiva de armónicos o *Selective Harmonic Elimination* (SHE), fueron de las primeras en ser aplicadas (4) (5).

Las técnicas SVM basan su funcionamiento en considerar un espacio de vectores, en el que cada vector representa un estado de conmutación de los IGBT que conforman el inversor. Para obtener un determinado vector de referencia de tensión, se calcula una combinación lineal de uno o varios vectores o estados de conmutación del inversor. Como las corrientes generadas serán sinusoidales, el vector de referencia se desplazará por todo el espacio vectorial y en cada momento, será el resultado de una combinación específica (o modulación) de ciertos vectores de conmutación.

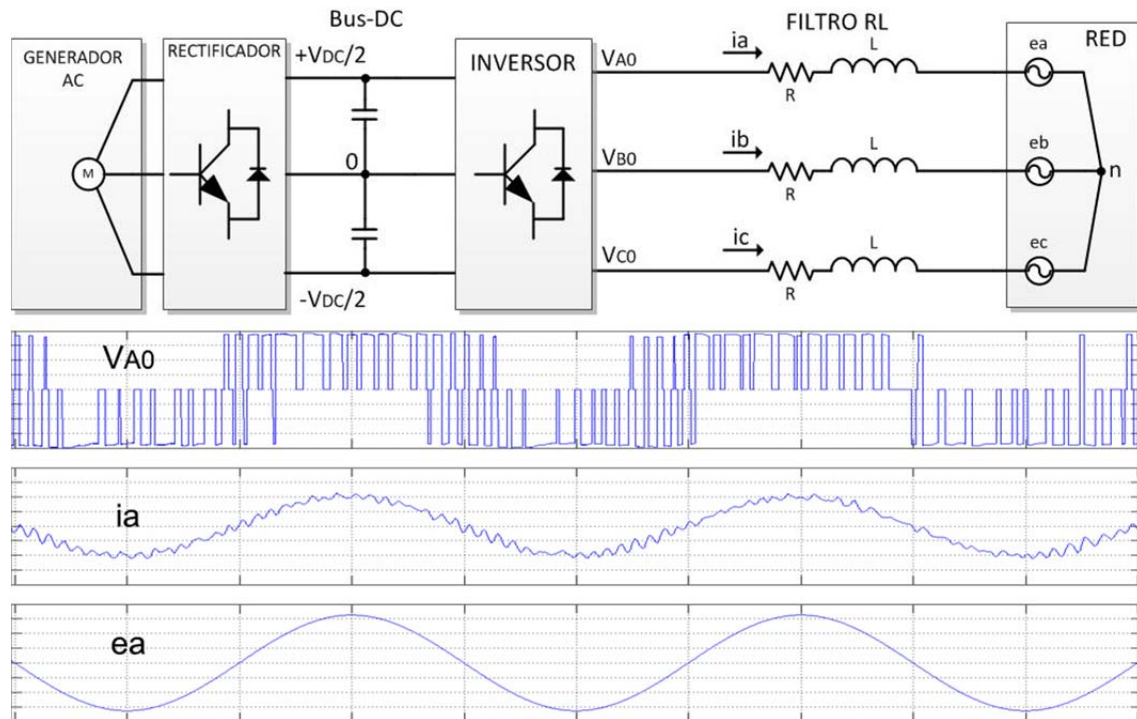


Figura 2. Señales involucradas en la generación de las corrientes de salida.

En (6) se muestra un controlador basado en la técnica SVM sobre un convertidor 3L-NPC, en el que se controla el desequilibrio del Bus-DC y se intentan reducir las pérdidas por conmutaciones, objetivos similares a los de la función de coste que se aplica en esta tesis. El mayor inconveniente de estas técnicas, radica en la complejidad de su formulación para definir la expresión de la modulación realizada en cada instante para seguir las referencias, ya que depende de las duraciones de las activaciones de cada IGBT (PWM).

Por otro lado, las técnicas SHE, usadas en convertidores multinivel NPC, se basan en usar métodos eficientes de modulación, capaces de reducir la distorsión armónica total (*THD*), disminuyendo o mitigando los armónicos generados, para así poder reducir la complejidad y precio de los filtros de red utilizados (7). Estos métodos, sin embargo, tienen como mayores inconvenientes su elevada complejidad (al fin y al cabo, son un



caso particular de SVM incluyendo ciertas restricciones), y por otro lado tienen un gran coste de implementación y desarrollo.

Para ciertas aplicaciones, se pueden usar técnicas que intenten reducir la complejidad del controlador. Es el caso del control directo de potencia o *Direct Power Control* (DPC). En esencia consiste en realizar una supervisión del error cometido en el seguimiento de las consignas de potencia activa y reactiva y, a partir de él, mediante el uso de tablas predefinidas, seleccionar el estado de conmutación del inversor. Tradicionalmente este tipo de controladores han sido desarrollados para aplicaciones de baja potencia utilizando convertidores de 2 niveles (8). No obstante, coincidiendo con el aumento de la demanda energética y la introducción de los convertidores de 3 niveles, se ha introducido la técnica de DPC en estos. En (9) se desarrolla un controlador basado en esta técnica, utilizando un generador de inducción doblemente alimentado o *Double Fed Induction Generator* (DFIG). La principal ventaja del control DPC, es la extrema simplicidad de operación. En cambio, su gran desventaja es que su diseño solo vale para el caso concreto de aplicación para el que se hayan obtenido las tablas. Si se produce algún cambio, ello obliga a redefinir las tablas. Por esta misma razón, resulta menos robusto que otros métodos ante caídas de tensión (huecos de red) o variación de parámetros.

También se han propuesto técnicas no lineales de control por histéresis o *Hysteresis Current Control* (HCC) (10). Estas técnicas tienen como mayores ventajas: una inherente protección contra sobre-intensidades, son muy robustas frente a variaciones de la carga, del filtro o de las tensiones de red, y sobretodo tienen una respuesta dinámica muy rápida. Por el contrario, hacen uso de comparadores que responden con dificultad a frecuencias de conmutación elevadas, provocando mayores errores en las corrientes generadas e incluso introduciendo errores de componente continua en ellas (11).

Hoy en día, la técnica más ampliamente usada consiste en generar las señales de control PWM a partir de la comparación entre una señal portadora de tipo rampa o triangular, de período conocido, y una señal de referencia o moduladora sinusoidal (12). Posteriormente, la señal PWM se aplica a los drivers que controlan a los IGBT como en el resto de controladores. La Figura 3 muestra un ejemplo ilustrativo de la generación de las señales PWM con el uso de señales portadoras y moduladoras.

La mayor ventaja de estas técnicas, es que normalmente presentan una frecuencia de conmutación baja de los IGBT, y por tanto las distorsiones que se introducen en las

corrientes generadas son de orden pequeño. Por otro lado, como inconvenientes puede destacarse: 1) el desequilibrio que se produce en el Bus-DC, tema que se tratará ampliamente en esta tesis, y que tiene una gran relevancia en el funcionamiento del convertidor; y 2) la relativa complejidad de generación de las señales portadoras y moduladoras adecuadas. En trabajos como el presentado en (13), se realiza el control de un convertidor back-to-back de 3 niveles, usando esta técnica de generación PWM, en el que además se controla la distorsión armónica.




Figura 3. Generación de señales de control de los IGBT usando la técnica de PWM.

No obstante, ninguno de estos métodos permite de manera rápida y sencilla, la inclusión en el control de otras especificaciones a veces necesarias en el funcionamiento del sistema, como el control de la frecuencia de conmutación, el desequilibrio del Bus-DC que se produce en el inversor, o incluso el confinamiento total de los armónicos introducidos. Los métodos de control expuestos con anterioridad, cumplen con las especificaciones para las que fueron diseñados, pero en cambio resulta complicado que puedan atender al cumplimiento de nuevas especificaciones añadidas con posterioridad.

Como alternativa a los métodos tradicionales, surgen las técnicas de Control Predictivo basado en el Modelo o *Model Predictive Control* (MPC) (14) (15) (16). Estas técnicas consisten en aplicar un modelo matemático que describe el comportamiento del inversor, para poder predecir el funcionamiento futuro del mismo y así poder controlarlo. Los algoritmos MPC pueden adaptarse, además, a cualquier tipo de convertidor y topología, como por ejemplo en (17), en el que se implementa un control predictivo sobre un inversor de 4 niveles con topología *Flying Capacitor*, en el cual los

IGBT se unen mediante condensadores, en vez de a un punto neutro común, como en la topología NPC. Esta versatilidad, hace que sea la técnica adoptada en muchos de los trabajos publicados recientemente relativos al control de sistemas de electrónica de potencia (18). En (19) se muestra una recopilación actual de todos los métodos utilizados para el diseño de controladores aplicados a convertidores de potencia, enfocando el estudio en los que hacen uso de un algoritmo MPC, detallando los diferentes métodos, casos de aplicación y resultados obtenidos.

El gran inconveniente de esta técnica, es que en muchas ocasiones la predicción a partir de modelos matemáticos, supone una elevada carga computacional, que se traduce en tiempos de cómputo elevados, que a su vez están limitados por el período de muestreo empleado en el control. Otro aspecto negativo, es que la frecuencia de conmutación de los IGBT aumenta respecto a la empleada en las técnicas de PWM lineal y además tiende a ser variable. Por tanto, la distorsión armónica total que se introduce en la red puede ser mayor y estar fuera de control si no se toman las medidas adecuadas. Esto hace imprescindible, que, en mayor o menor medida, los algoritmos MPC se deban diseñar considerando como un aspecto importante, el nivel de armónicos que se generan. Así surgen variantes del MPC como el Control Predictivo Generalizado o *Generalized Predictive Control* (GPC) (20) o el explícito, *Explicit Model Predictive Control* (EMPC) (21), con el objetivo de conseguir una frecuencia de conmutación constante de los IGBT, a costa de un aumento sustancial de la complejidad de su operativa.

Los métodos MPC están adquiriendo gran importancia en el campo del control de los convertidores multinivel, gracias a los avances alcanzados en la mejora de su rendimiento. Por otro lado, su elevada carga computacional puede disminuirse abordando un modelado discreto del sistema, reduciéndolo de esta manera a un conjunto de estados finitos o únicos estados en los que puede estar el inversor. Es así como surge el Control Predictivo sobre un conjunto finito de estados o FCS-MPC (*Finite Control Set-Model Predictive Control*) (22). Esta evolución, asocia a cada estado una configuración concreta de tensiones de salida del inversor, cuyas corrientes de salida están descritas por la ecuación de la malla de la línea de red. Este modelo matemático, se utiliza para predecir su comportamiento, generando las tensiones de línea adecuadas a la salida del inversor, y posteriormente las corrientes. Además, su facilidad de implementación en plataformas de alto rendimiento como las FPGAs (23) o en sistemas de microprocesadores o DSP (*Digital Signal Processors*) (24) (25), las convierten en una sólida alternativa a las técnicas de control clásicas.

La Figura 4 ilustra la inclusión de un bloque de Control Predictivo dentro del esquema de generación de energía a partir de un convertidor 3L-NPC que es la plataforma usada para la investigación aquí descrita.

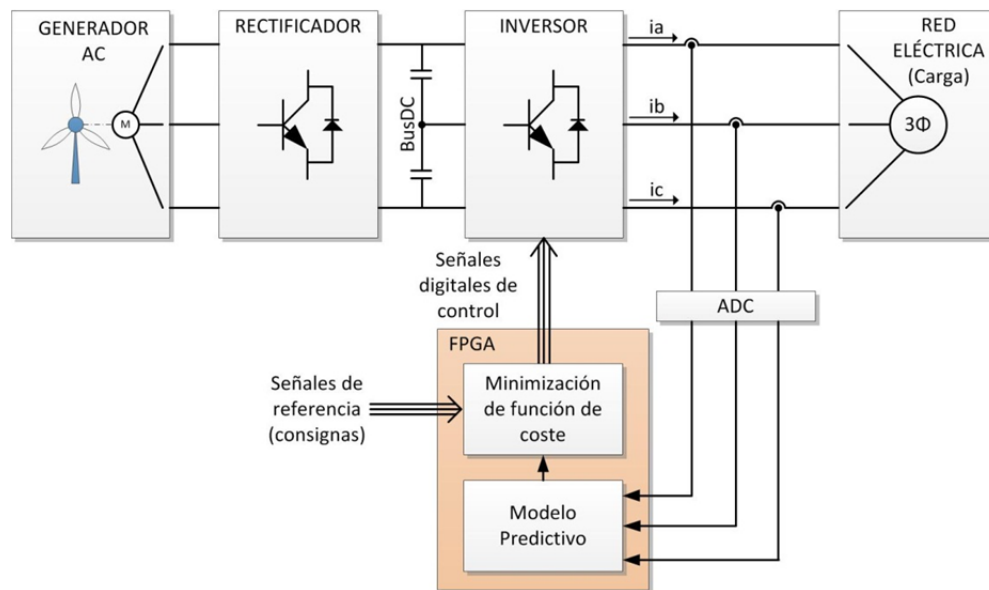


Figura 4. Inclusión de un Control Predictivo en el sistema de generación de energía basado en un convertidor de 3 niveles.

Como se observa, el objetivo principal del Control Predictivo, es buscar de entre todos los estados posibles del sistema, aquel que haga que se minimice cierta función de coste o de calidad. Una vez encontrado, se establece como estado próximo, configurando al convertidor para ello a través de las señales de control de los IGBT. Estas señales siguen teniendo aspecto de una modulación PWM, salvo que no se obtienen mediante una modulación propiamente dicha, sino que es el resultado implícito de la minimización de la función de coste para un conjunto finito de estados. Por tanto, el algoritmo FCS-MPC no necesita de modulaciones intermedias como es el caso del GPC o EMPC, ello hace que se reduzca el coste de implementación y la complejidad de su operativa (19).

La función de coste pondera las distintas especificaciones de diseño del controlador, considerándose como objetivo fundamental el seguimiento (o *tracking*) de las consignas de corrientes requeridas. Por otro lado, la versatilidad de operar con funciones digitales, permite incluir en dicha función de coste, diferentes términos o sumandos, según los objetivos del control, ponderados cada uno de ellos mediante un

factor peso, que determinarán en gran medida el comportamiento final del sistema (26).

Para el caso de la planta que se utiliza en esta tesis, basada en un convertidor 3L-NPC, hay dos objetivos de control importantes que deben ser siempre incluidos en la función de coste y que son indispensables para el buen funcionamiento del control de corriente:

1. Minimización de las desviaciones de las tensiones del Bus-DC, y por tanto su desequilibrio, producidas durante los cambios de estados del inversor (conmutaciones de los IGBT). Las tensiones del Bus-DC se emplean para fijar los niveles de tensión que se tendrán en las salidas del inversor. Posteriormente, se verá como en un inversor de 3 niveles, estas tensiones se definen como  $V_1=+V_{DC}/2$ ,  $V_2=0$  y  $V_3=-V_{DC}/2$ , siendo  $V_{DC}$  la tensión continua máxima aportada por el Bus-DC, y el nivel 0 la tensión del punto central o neutro del bus. En un caso ideal, en valor absoluto  $|V_1|$  y  $|V_2|$  deben ser idénticos, estando equilibrado el Bus-DC. No obstante, en algunos estados se crean corrientes de fuga en el punto central que hacen que  $|V_1| \neq |V_2|$  produciéndose un desequilibrio en el Bus-DC cuyos efectos deben mitigarse.
2. La frecuencia de conmutación de los IGBT es el otro gran factor a tener en cuenta en estos convertidores. Un aumento considerable de la frecuencia de conmutación, hace que la potencia disipada en ellos sea mayor, y por tanto aumentarán las pérdidas, afectando al rendimiento global del convertidor. Por ello, se debe asegurar una frecuencia de conmutación de los IGBT lo más baja posible, o al menos acotándola a un máximo. Trabajos ya realizados en esta línea como en (27), basados en las técnicas de SHE anteriormente comentadas, plantean el uso de un modelo con una función de coste en la que se utilizan factores de peso para controlar cada uno de los armónicos que se introducen en la red, disponiendo de los valores óptimos pre-calculados de forma offline.

Para cada uno de estos dos objetivos de control, existirá un término ponderado en la función de coste, con un factor multiplicativo (peso) que deberá aumentarse para aumentar la importancia de estos objetivos de control, frente al *tracking* o seguimiento de las consignas, que se considerarán con peso la unidad. Para asignar valor a estos pesos, comúnmente se ha recurrido al método prueba y error, mediante la experimentación recursiva, hasta encontrar los valores concretos para los pesos de la

función de coste, que permitían alcanzar las especificaciones del diseño. En trabajos similares con convertidores multinivel como en (28) (29) (30), se hace una clara referencia a la necesidad de encontrar un método para asignar valores a los factores de peso.

Aunque existen situaciones o casos de aplicación en los que se ha demostrado que no es necesaria una función de coste con pesos (31), la definición de ella misma y el valor de cada uno de los pesos es crucial para la mayoría de los casos, por lo que la asignación de valores a los pesos, deviene en la tarea más importante del diseño del controlador predictivo (32) (33). En (28) o (34), donde se realiza el diseño de un controlador predictivo para un convertidor 3L-NPC en el que los objetivos de control son semejantes a los antes mencionados, se evidencia que la correcta asignación de los pesos, es un tema que requiere de una especial atención, y que, a día de hoy, constituye una línea de investigación abierta.

En el trabajo descrito en (30), queda de manifiesto que un ajuste empírico no es un procedimiento robusto, por lo que se proponen diferentes soluciones, como diferentes rangos de valores en los que deberían estar los factores de peso; y se desarrollan procedimientos que ayudan a obtener los valores óptimos de los pesos, como, por ejemplo, utilizar una función de coste normalizada.

Sin embargo, estos métodos siguen necesitando de la intervención del diseñador del controlador, y del testeo del sistema en multitud de puntos de trabajo. Y otro aspecto no menos importante en los trabajos descritos en la bibliografía, es que una vez se asignan los valores, estos se mantienen constantes durante todo el funcionamiento del controlador, aunque pueda cambiar el tipo de consignas o las condiciones de funcionamiento del convertidor. Es decir, se utilizan funciones de coste estáticas. Si alguno de los parámetros del modelo o del sistema cambia, los pesos seleccionados se deben recalcular, volver a realizar un estudio y re-implementar el controlador. Esto puede ser válido en sistemas en los que no cambien las referencias y los parámetros sufran pequeñas variaciones. Queda de manifiesto pues, que resulta necesario tener una alternativa general que permita solucionar el problema de encontrar los pesos de la función de coste y que pueda funcionar de forma dinámica.

A lo largo de esta tesis se demostrará cómo los índices de calidad de funcionamiento del convertidor son dependientes de los factores de peso de la función de coste y de las referencias de potencia, por lo que, ajustando dichos pesos, se pueden llegar a mejorar o a encontrar puntos de funcionamiento óptimos. Para que estos ajustes sean

útiles, se deben realizar de forma automática y después de cada cambio de consignas o condiciones. En otras palabras, se propone una función de coste dinámica.

Existen algunos trabajos previos, para otro tipo de plantas, en los que se ha utilizado un modelo de función de coste dinámica en controladores predictivos, para conseguir una adaptación ante cambios de sus parámetros. En (35) se describe un método analítico para controlar de forma dinámica y online, los pesos de la función de coste para un algoritmo FCS-MPC que reduce el rizado en señales de un inversor de dos niveles. Incluso existen algunos trabajos de aproximaciones para otros modelos de convertidores de potencia (en este caso de 4 niveles) en los que se intenta modificar los factores de peso de forma online para intentar regular la frecuencia de conmutación de los IGBT, de una manera muy simple, mediante el uso de tablas (36). Otros trabajos como (32) proponen una estrategia basada en lógica borrosa, en la que se divide la función de coste en sub-funciones y para cada una de ellas se utilizan reglas específicas de decisión para encontrar los valores de los pesos.

El correcto funcionamiento de los algoritmos MPC, está condicionado a que tanto los valores de inductancia y resistencia de la red eléctrica, como los de los componentes de los filtros que se utilizan, se mantengan estables y coincidan con aquellos para los que fue diseñado el controlador. Es decir, el control tiene que estar sintonizado para las condiciones de funcionamiento en las que se ha de utilizar. Sin embargo, en un caso real es habitual la existencia de incertidumbres de modelado y perturbaciones, que pueden exigir la reconfiguración del controlador. En este trabajo se ha evaluado la capacidad del controlador MPC para minimizar el efecto de estos cambios, incluyéndose algunos bloques que optimicen el algoritmo clásico, dotándole de cierto grado de adaptabilidad. Además, en este trabajo se demuestra cómo el comportamiento del convertidor es muy dependiente de las referencias de potencia activa y reactiva deseadas, por lo que una función de coste estática no resulta viable cuando se producen cambios en estas referencias. Estudiando la relación que existe entre los pesos de la función de coste y las referencias de potencia, se proponen diferentes alternativas para implementar un método que permita trabajar con una función de coste dinámica. Finalmente, se propone una metodología que permite optimizar el funcionamiento del sistema, definiendo un novedoso método que se ha denominado Modelo de Control Predictivo Adaptativo o A-MPC.



### **1.3 Alternativas Tecnológicas para Implementar el Algoritmo de Control**

Para implementar algoritmos en los que se necesita mucha potencia de cálculo, uno de los primeros aspectos que hay que evaluar, es la plataforma sobre la que se implementará. Dependiendo de las necesidades que se tengan, hay que evaluar el uso de las diferentes posibilidades tecnológicas existentes, y ver cuál es la que más se adecúa a las necesidades.

Para el caso que nos ocupa, hay dos aspectos que hay que tener en cuenta. El primero de ellos, es que se necesitará operar con gran cantidad de datos, ya que el Control Predictivo, trabaja con señales digitalizadas y operaciones matemáticas sobre estas, y es imprescindible usar plataformas que tengan la suficiente capacidad de cálculo. El segundo aspecto es la rapidez del sistema. En un sistema con un convertidor de 3 niveles funcionando sincronizado con la red eléctrica trifásica, la velocidad de cálculo debe ser suficiente para que entre muestra y muestra se puedan hacer todas las operaciones necesarias. La frecuencia de muestreo por otro lado, debe asegurar que el muestreo sea adecuado para que la respuesta del sistema sea rápida. Las frecuencias de muestreo habituales en estos sistemas, están en el orden de 10 - 50kHz, asegurando al menos unas 200 muestras en cada ciclo de señal de 50 Hz.

Una vez se encuentre el mejor método de control y mecanismo de optimización que permita dar adaptabilidad al sistema, se deberá implementar todo el modelo del controlador en alguna plataforma hardware concreta. Comúnmente, los sistemas de Control Predictivo se han venido implementando en plataformas basadas en procesadores digitales específicos o DSP (24) (25) (28) (37). Un ejemplo de utilización del mismo convertidor 3L-NPC que se usará en este trabajo, aunque implementado en DSP y basado en técnicas de modulación PWM, donde además se ha diseñado la interfaz de control del mismo, es (38). No obstante, la implementación en este tipo de plataformas, tienen como mayor inconveniente el retardo inherente que se produce en una ejecución secuencial de todos los pasos que se deben realizar para obtener el estado óptimo. Esto se traduce, primeramente, en que dicho estado puede que no se aplique siempre en el mismo instante de tiempo. Y segundo, a medida que se necesite más capacidad de cómputo para integrar nuevas funcionalidades y condiciones de contorno, como es el caso de este trabajo de investigación, dicho retardo puede verse

incrementado. En publicaciones como (39) o (40) se hace clara referencia a este inconveniente, y cómo es indispensable implementar maneras de corregir el problema.

Lo más común cuando se implementan controladores FCS-MPC sobre DSP, es que exista un retardo de todo un período de muestreo hasta que se aplica el estado óptimo. Es decir, en cierto instante, se obtienen las muestras de las corrientes, tensiones y otras señales necesarias para aplicar el control, y durante todo ese período de muestreo se realizan los cálculos. Una vez terminado de aplicar el modelo el estado óptimo obtenido, se aplicará en el siguiente instante de muestreo. De esta forma, se asegura que siempre se aplican los cambios en el estado de conmutación al comienzo de un nuevo periodo de muestreo. En trabajos como (41), se realiza un estudio para intentar compensar el retardo inherente del control sobre estas plataformas. En estos casos, queda claro que puede resultar una mejor opción, utilizar sistemas de procesamiento concurrente, pudiendo paralelizar la ejecución de las operaciones.

Para solventar este problema, la utilización de plataformas como las FPGA resulta una atractiva solución (42) (23) (43). Utilizando estas plataformas, se consigue una ejecución concurrente de todas las tareas, previamente paralelizadas. En trabajos publicados fruto de esta investigación, se ha demostrado como la paralelización consigue aprovechar mejor los recursos de las FPGA, haciendo que se acorten los tiempos de cálculos, y por tanto se tenga un mayor margen para acomodar la ejecución de algoritmos más complejos dentro del período de muestreo del control. En (44) y (45) se han realizado estudios sobre las diferentes opciones de implementación en FPGA del algoritmo de Control Predictivo aquí descrito, realizando un estudio y una comparativa de los métodos de segmentación, planificación de operaciones, grados de paralelización y métodos combinados.

Aparte de la elección de un tipo de plataforma concreta, los diseños se deben realizar de tal manera que el código aproveche al máximo posible los recursos de la plataforma. Haciendo uso de estudios específicos ya realizados sobre este tema, y usando técnicas y algoritmos como los descritos en (46) y (47), se puede implementar el Control Predictivo con garantías sobre una FPGA. Uno de los principales inconvenientes que tiene el uso de estas plataformas, es que se debe encontrar un equilibrio entre los recursos consumidos por el algoritmo, limitación propia de la FPGA que se utilizará, y el tiempo de ejecución de todas las tareas, que dependerá de la complejidad del algoritmo en sí, y del intervalo de operación permitido.

## 1.4 Alternativas para el Desarrollo del Sistema Adaptativo

En sistemas de MIMO (múltiples entradas, múltiples salidas) de cierta complejidad, cuyo funcionamiento se ve afectado por diversas variables de estado internas, puede resultar difícil obtener un modelo preciso, que permita un control con varios objetivos. En el caso que nos ocupa, se trata de diseñar e implementar un método capaz de encontrar los valores adecuados para los factores de peso de la función de coste del Algoritmo de Control Predictivo, de modo que se alcancen determinados objetivos de control (criterios de calidad) ante cualquier referencia de potencia. Como se ha comentado ya, el primer paso consiste en obtener un modelo que describa matemáticamente la planta. Para ello existen muchas alternativas que utilizan como base, un conjunto de observaciones previas del comportamiento del sistema, para de esta manera obtener o deducir las relaciones entre las diferentes variables que intervienen.

El sistema utilizado en este estudio, como bien se ha explicado ya, consiste en un convertidor 3L-NPC controlado por un algoritmo de Control Predictivo que predice el siguiente estado óptimo de funcionamiento del sistema para conseguir minimizar una función de coste. Dicha función de coste, puede tener varios términos, pero en nuestro caso se proponen tres términos fundamentales: el seguimiento de las consignas de corriente o *tracking*, el desequilibrio en las tensiones del Bus-DC, y la frecuencia de conmutación de los IGBT para mejorar el rendimiento en potencia del convertidor. Estos tres términos han sido seleccionados porque guardan relación directa con los parámetros de calidad más comunes de los inversores de potencia, presentando una complejidad computacional inferior, y por tanto una mayor facilidad de implementación en plataformas como las FPGAs. Así por ejemplo, el error de tracking y el desequilibrio del Bus-DC, están estrechamente relacionados con la distorsión armónica de las corrientes a la salida del inversor, y la frecuencia de conmutación lo está con la eficiencia en potencia del mismo.

Aunque en este trabajo solo se han incluido estos tres términos, el método de Control Predictivo basado en la utilización de una función de coste, podrían incluir otros términos para controlar funcionalidades más concretas. En (48) se hace un estudio para la eliminación selectiva ciertos armónicos introducidos en la red utilizando la transformada discreta de Fourier enventanada. No obstante, añadir este término a la

función de coste aumentaba en gran medida la complejidad computacional del algoritmo, pues implica realizar una transformada de Fourier para cada armónico de los que se desea controlar, y realizarlo para cada uno de los posibles estados de conmutación, cada instante de muestreo.

Como también se ha comentado, cada uno de estos términos se pondera con un factor de peso con cuyo ajuste se consigue la adaptabilidad del sistema. Por tanto, los factores de peso son los parámetros de ajuste del control y deberá encontrarse un método sistemático que permita calcular su valor.

Para simplificar el proceso de ajuste, sin pérdida de generalidad, se puede asignar al factor de peso del *tracking* de corriente el valor de 1, y ajustar los otros dos factores de peso para conseguir diferentes objetivos de control. A modo de ejemplo y para entender mejor esta aproximación, considérese el caso en el que se trabaja con tres factores de peso para ponderar el error de *tracking*, el desequilibrio del Bus-DC y la frecuencia de conmutación, pudiéndolos representar mediante el vector  $[\lambda_1, \lambda_2, \lambda_3]$  respectivamente, y que estos tomen los valores  $[1, 1, 1]$ . Como es obvio, en este caso, los tres términos tienen el mismo peso en la función de coste. Si los factores de peso fuesen  $[1, 2, 2]$ , esto implicaría que el desequilibrio del Bus-DC y la frecuencia de conmutación, tienen el doble de peso que el *tracking* en la función de coste, y tendría el mismo efecto que si por ejemplo se usasen los factores  $[0.5, 1, 1]$ ,  $[2, 4, 4]$  o  $[0.3, 0.6, 0.6]$ . De los ejemplos anteriores, se puede deducir que los factores de peso del desequilibrio, y la frecuencia de conmutación, se pueden normalizar a la unidad, siendo 1 el factor de peso del *tracking*. Con esto, se consigue que el método de adaptación en realidad solo necesite ajustar dos parámetros: Los dos factores de peso que se definirán como  $\lambda_{DC}$  y  $\lambda_{SW}$  para el desequilibrio del Bus-DC y la frecuencia de conmutación respectivamente.

Una vez establecidas las variables de salida, se necesitan definir los objetivos de control y las entradas al método de ajuste propuesto. Como se demostrará en este trabajo, en los inversores de potencia controlados por algoritmos de Control Predictivo, las referencias de potencia del convertidor influyen en gran medida en el funcionamiento del mismo, por ello, la potencia activa que denotaremos con la letra  $P$ , y la potencia reactiva con la  $Q$ , son dos entradas obligadas. Las otras entradas deben ser objetivos de control que permitan cuantificar de alguna manera el buen o mal comportamiento del convertidor. En esta tesis se proponen los siguientes objetivos de control o criterios de calidad a optimizar:

- La desviación media, o error medio de corriente en amperios que se produce entre las corrientes generadas y las consignas o referencias, que se denominará como  $\Delta i_{\alpha\beta}$ . Este término, cuyo valor instantáneo está incluido en la función de coste, es el de mayor importancia en todo el proceso, pues el principal objetivo de control debe ser seguir las referencias. Está directamente relacionado con el error de *tracking* incluido en la función de coste y por tanto en la calidad de la señal sinusoidal de las corrientes de salida respecto a las referencias ideales (amplitud, fase y frecuencia).
- El error medio o desviación media entre las dos tensiones del Bus-DC respecto al punto central o nivel 0V, lo que se conoce como desequilibrio del bus, al que se denominará como  $\Delta V_c$ . Este parámetro protege de sobretensiones en los transistores IGBT del inversor y además influye en la distorsión armónica de las corrientes de salida, pues cuando se producen estos desequilibrios las tensiones de salida del inversor no son simétricas ( $\pm V_{DC}/2$ ).
- La frecuencia media de conmutación de los IGBT,  $f_{SW}$ , evaluada por el mismo controlador, debido a que esta frecuencia depende directamente del número de cambios en los estados en los cuales se puede configurar el convertidor. Este parámetro influye en la eficiencia en potencia del inversor, ya que a mayor frecuencia de conmutación, se producen mayores pérdidas de potencia por calentamiento en los IGBT, y por tanto se reduce la eficiencia.
- La distorsión armónica total o THD del sistema, directamente dependiente de la relación que existe entre el nivel del armónico fundamental de la señal, en este caso 50Hz, y la suma del resto de armónicos que se introducen. Este parámetro es complicado obtenerlo e introducirlo en la función de coste directamente, ya que exigiría el cómputo de las predicciones de las componentes frecuenciales que se obtendrían para cada uno de los posibles estados evaluados. Para realizar este cómputo sería necesaria disponer de un histórico de muestras almacenadas en un *buffer*. Por ello, el comportamiento del sistema respecto a este término se evaluará a partir de los resultados obtenidos durante la simulación de su funcionamiento.

Recopilando lo dicho anteriormente, se puede concluir que el método de ajuste de un Algoritmo de Control Predictivo Adaptativo sobre un convertidor 3L-NPC tendrá como entradas la potencia activa deseada  $P$ , la potencia reactiva deseada  $Q$ , la desviación media de corriente permitida  $\Delta i_{\alpha\beta}$  respecto a las referencias, el desequilibrio permitido de las tensiones del Bus-DC  $\Delta V_{DC}$ , la frecuencia media de conmutación  $f_{SW}$  de los

IGBT y la distorsión armónica o THD exigible por normativa. Con estas entradas, y a partir del método utilizado para modelar el comportamiento del sistema, se deben calcular automáticamente los factores de peso de la función de coste  $\lambda_{DC}$  y  $\lambda_{SW}$ , asegurando que el funcionamiento del convertidor siga las consignas de entrada. Con todo lo anterior se establece que, entre referencias y objetivos de control, se tendrán 6 entradas y que las salidas serán las señales de control de los IGBT del inversor tal como se muestra en la Figura 5. Además, para la aplicación del modelo predictivo, serán necesario muestrear ciertas variables o señales como se verá posteriormente.

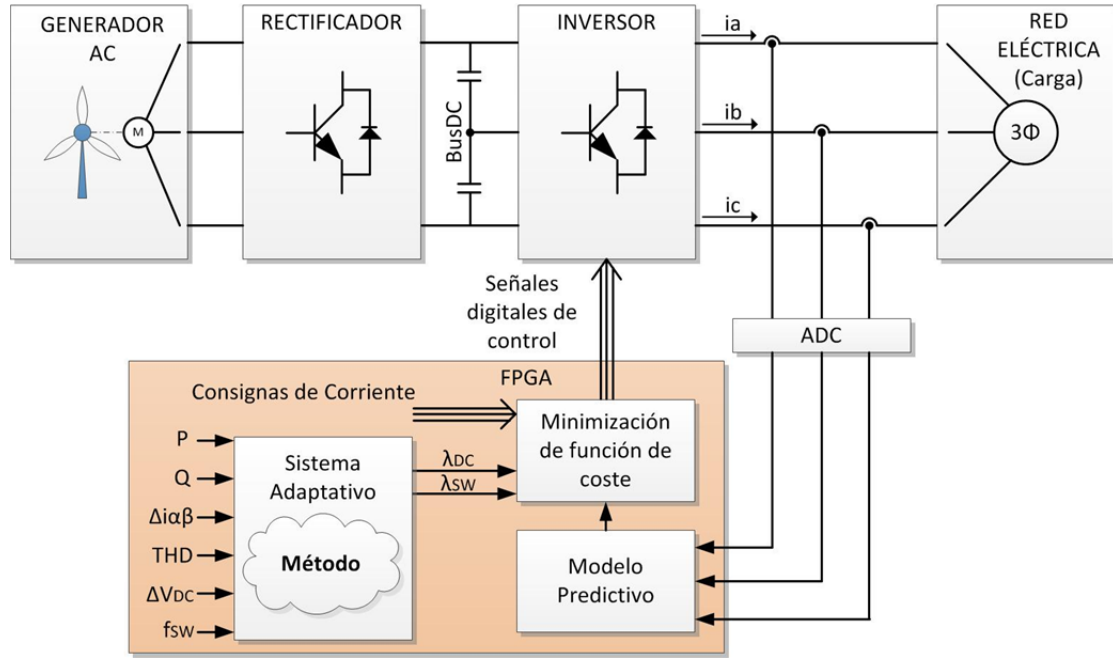


Figura 5. Inclusión de un método de adaptabilidad en el Control Predictivo para un convertidor 3L-NPC.

Existen diversos métodos, ya propuestos por otros autores, para resolver el problema de optimización anteriormente planteado. A continuación, se comentarán algunas de las alternativas más plausibles para diseñar el sistema adaptativo mostrado en la figura anterior. Posteriormente se evaluará si es factible, o no, su implementación en tiempo real.

Las expresiones mostradas en [1], indican de forma genérica, la relación entre las variables de entrada al proceso de optimización y las salidas del mismo.

$$\begin{aligned}\lambda_{DC} &= f_1(P, Q, \Delta i\alpha\beta, THD, \Delta V_{DC}, f_{sw}) \\ \lambda_{SW} &= f_2(P, Q, \Delta i\alpha\beta, THD, \Delta V_{DC}, f_{sw})\end{aligned}\quad [1]$$

Un método sencillo para resolver el problema de optimización es mediante la regresión lineal múltiple. Sin embargo, esta solo será adecuada si las variables de salida, o

variables dependientes, pueden expresarse como combinación lineal de las variables de entrada llamadas en este ámbito, variables explicativas (49) (50). No obstante, aunque en muchos sistemas la relación entre las variables no es puramente lineal, se puede realizar una aproximación como si así lo fuera, por lo que es una alternativa que se valorará en esta tesis.

La resolución aplicando un modelo de regresión lineal, requiere disponer de una serie de observaciones del comportamiento del sistema, para posteriormente resolver el problema de optimización mediante mínimos cuadrados (51).

Otro método muy utilizado para casos en los que aparentemente no existe una relación directa o clara entre las variables de entrada y de salida, es la utilización de redes neuronales artificiales o ANN (*Artificial Neural Network*). Estas redes están basadas en el modelo neuronal natural, y, tras una fase de entrenamiento, pueden resolver problemas no lineales de clasificación o de optimización. Las redes neuronales deben su nombre a que están compuestas por múltiples elementos operacionales denominados neuronas, que a su vez están interconectados entre ellos en diferentes capas, formando una red de interconexiones. La Figura 6 muestra la estructura genérica de una ANN. Existen muchas consideraciones a la hora de implementar una ANN, ya que se pueden diseñar múltiples estructuras o arquitecturas para la red de interconexiones, distribuir las neuronas en varias capas cada una de ellas con cierto número de estas, utilizar diferentes tipos de entrenamientos, usar recurrencia o no, etc. (52). No obstante, atendiendo al patrón de conexiones que presentan, pueden distinguirse dos tipos básicos de ANN:

- Redes neuronales de propagación hacia delante (*Feedforward ANN*): De una o múltiples capas, las señales siempre se propagan desde la capa de entrada hacia la capa de salida.
- Redes neuronales recurrentes (*Feedbackward ANN*): Presentan al menos un ciclo cerrado de interconexiones en sus neuronas, en el que la salida de una neurona es entrada de otra.

En esta tesis, las ANN serán parte de la propuesta de solución al problema de optimización, para lo que se analizarán diferentes tipos de estructuras de redes neuronales, y se optará por aquella que, conjuntamente, permita resolver el problema y a la vez sea factible de implementar para un funcionamiento en tiempo real.




Figura 6. Estructura genérica de una red neuronal artificial o ANN.

Por tanto, las ANN representan una alternativa que no requiere de un modelo específico predefinido y que pueden adaptarse a multitud de problemas, si bien su ajuste y arquitectura óptima para un determinado caso, no responde a una metodología sistemática, si no que depende en gran medida de la experiencia del diseñador. Por ello, es muy común y recomendado, hacer uso de herramientas computacionales que ayuden a evaluar el funcionamiento del uso de las ANN. En este caso, una herramienta muy usada es MATLAB, y concretamente un conjunto de funciones ya predefinidas para la configuración de aspectos relevantes en los diseños, métodos de entrenamiento y simulación de resultados con las redes neuronales. Estos conjuntos de funciones, a menudo se engloban en útiles herramientas de usuario, como las *toolbox* de MATLAB, entre las que hay algunas de uso específico en redes neuronales (53).

Existen numerosos trabajos previos que demuestran la flexibilidad y capacidad de las redes neuronales para modelar comportamientos, siendo, además, muy frecuente, su implementación en plataformas de gran capacidad computacional, como las FPGA (54) (55). No obstante, en esta tesis, se propone emplear la red neuronal para resolver el problema de adaptabilidad del controlador a distintos objetivos de control y referencias de entrada.



Otra alternativa para enfrentar problemas de predicción, optimización o clasificación es la lógica difusa. Se usa normalmente en procesos deductivos y de toma de decisiones y, por tanto, podría ser de aplicación en Control Predictivo para sistemas no lineales. En trabajos como (56), se ha utilizado la lógica difusa como herramienta para el control de un convertidor monofásico conectado a la red eléctrica. No obstante, la complejidad que plantean convertidores de mayor potencia como los 3L-NPC, hace que aún no se haya desarrollado una investigación sobre la aplicación de la lógica difusa para estos casos.

La idea base de la lógica difusa es la utilización de “reglas de inferencias”, aplicadas a conjuntos no delimitados. Se caracteriza por la gran flexibilidad o tolerancia con la imprecisión. A cada una de las variables de entrada, se les aplica, según su valor, un cuantificador específico, como por ejemplo “alto”, “medio” o “bajo”. Una vez se tienen todas las variables cuantificadas, se aplican las reglas de inferencias, que proporcionan las variables de salida, también etiquetadas. Este enfoque permite que no se opere directamente con valores, sino con estados y condiciones, de ahí el nombre de “difusa”.

Existen diversos trabajos previos que describen aplicaciones de la lógica difusa para supervisión de controladores que intentan predecir comportamientos, aplicados a generadores o inversores de corriente (57) (58), aunque en la mayoría de casos, el número de variables que intervienen es menor y la complejidad más reducida, que el caso planteado en esta tesis. El principal inconveniente del empleo de este método para aproximar el comportamiento en el caso descrito en esta tesis, es la dificultad de establecer las relaciones entre las variables de entrada y salida. Para ello sería necesario un vasto conocimiento del sistema en un amplio abanico de casuísticas, lo que significaría una tarea muy ardua o imposible.

## **1.5 Objetivos de la tesis doctoral**

Teniendo en cuenta los aspectos referentes al Control Predictivo de inversores de potencia, los objetivos que se pretenden conseguir en esta tesis, se pueden sintetizar brevemente como los siguientes:

1. Abordar el control de un inversor de potencia aplicando un modelo matemático que predice su comportamiento.

2. Conseguir bajos tiempos de actuación en la aplicación del algoritmo de control que permitan aplicar el estado antes del siguiente ciclo de muestreo de las señales de entrada al controlador.
3. Encontrar un método fiable para describir la dependencia del controlador ante cambios en las consignas y parámetros de calidad, y que sea extrapolable a otras configuraciones o plataformas.
4. Aplicar el método encontrado para realizar la optimización del Control Predictivo clásico aplicado al caso concreto de un convertidor 3L-NPC, para que se adapte ante estos cambios.
5. Demostrar que el método encontrado puede ser fácilmente implementado en una FPGA.

## **1.6 Organización del Documento**

El siguiente trabajo de tesis se estructura de la siguiente manera.

El CAPÍTULO 2 está dedicado a explicar la implementación del algoritmo de Control Predictivo simple sobre un convertidor 3L-NPC. En él se abordarán los fundamentos teóricos del controlador, así como toda la operativa que describe el comportamiento, modelado y el núcleo de funcionamiento del mismo. Se expondrá la problemática del control de un MPC clásico y las posibles debilidades del sistema. Una vez se hayan identificados los problemas, en el CAPÍTULO 3 se propone el control Predictivo Adaptativo o A-MPC para minimizar dichos problemas. Se evalúan cuantitativamente los factores cuyas variaciones influyen negativamente, y además se muestran las relaciones que existen entre ellos, mediante el estudio del comportamiento del sistema en diferentes puntos de trabajo y configuraciones. Por último, se realiza un estudio de las posibles soluciones para implementar el algoritmo propuesto A-MPC.

El CAPÍTULO 4 se centra en el diseño y desarrollo de una ANN para resolver el problema de la optimización del Control Predictivo en tiempo real. De igual manera, se propone una metodología sistemática de implementación de la solución más adecuada, para posteriormente en el CAPÍTULO 5, describir los resultados experimentales y prácticos de la implantación de dicha solución.

Para finalizar, el CAPÍTULO 6 recoge las conclusiones obtenidas en este trabajo, viendo el grado de cumplimiento de los objetivos y planteando las posibles mejoras y líneas de posibles trabajos futuros.



# CAPÍTULO 2. CONTROL PREDICTIVO EN UN CONVERTIDOR 3L-NPC

## 2.1 Introducción

El Control Predictivo en convertidores multinivel, como se ha comentado en el capítulo introductorio, basa su funcionamiento en predecir el comportamiento futuro del inversor, para así estimar el valor de corriente que se generaría en cada una de las tres ramas. Un inversor trifásico de 3 niveles ( $+V_{DC}/2, -V_{DC}/2$  y  $0$ ), podrá estar en 27 estados diferentes ( $3\text{niveles}^{3\text{fases}}$ ) (4). Dicho esquema de control, debe asegurar por encima de todo, que las corrientes que se generen a la salida del inversor sean lo más parecidas posible a las corrientes de referencia obtenidas a partir de las consignas de potencia. Esta condición es comúnmente denominada como "*tracking*" o seguimiento de las consignas. En un funcionamiento básico, el controlador debe elegir como futuro estado aquel que genere unas corrientes reales que se asemejen lo máximo posible a las consignas. Sin embargo, resulta necesario controlar otros aspectos, que, de no hacerlo, harían inviable la aplicación de este algoritmo. Un ejemplo de ello, es el desequilibrio que se produce en el bus-DC por el hecho de existir corrientes por su punto neutro. Este desequilibrio puede provocar diferencias de tensiones en los condensadores que es necesario corregir, primeramente porque existe una limitación eléctrica de la tensión máxima que pueden soportar que se puede superar si el desequilibrio es excesivo; y segundo, porque al desequilibrarse estas tensiones, lo hacen también las de salida del inversor y se introducen errores en las corrientes generadas. Por ello, se hace necesaria una función de coste que valore o tenga en cuenta otros objetivos de control además del *tracking*.

La propuesta de Control Predictivo Adaptativo realizada en esta tesis, está basada en buena medida en los trabajos realizados en (42) y (23), a los que se ha añadido la capacidad de adaptabilidad y optimización, objetivo principal del presente trabajo. En este capítulo se muestran los conceptos fundamentales del control predictivo, así como sus debilidades, principalmente su elevada sensibilidad ante las variaciones de diferentes parámetros, para posteriormente proponer alternativas que las compensen.

## 2.2 Fundamentos Teóricos

A continuación, se describirá el modelado del inversor 3L-NPC, para, posteriormente, diseñar el control predictivo del mismo. En este estudio, se obviará el control del elemento rectificador del convertidor, asumiendo por tanto que es capaz de generar una tensión continua estable a partir de la cual se alimenta el inversor.

### 2.2.1 Modelo del Inversor 3L-NPC

El control predictivo requiere de un modelo matemático de la planta bajo control, en este caso un inversor 3L-NPC. El funcionamiento del inversor se puede modelar como un conjunto finito de estados, en los que para cada uno de ellos se obtiene un vector de tensiones de salida correspondientes a cada una de las fases de la red: ( $V_{AO}$ ,  $V_{BO}$ ,  $V_{CO}$ ). La Figura 7 muestra el circuito que conforma un inversor 3L-NPC, donde se puede ver que está compuesto por tres ramas, una para cada fase de salida, cada una de las cuales está compuesta a su vez por 4 IGBT lo que hace un total de 12 elementos de conmutación. Estos IGBT están asociados en semi-puentes o “*half-bridge*” de tal manera que, por ejemplo, para la primera rama, el IGBT S1 está asociado en semi-puente con el S3, y el S2 en semi-puente con el S4, funcionando estos de forma opuesta: cuando S1 está conduciendo o en “ON”, S3 está cortado o en “OFF”, cumpliéndose la misma relación en el otro semi-puente compuesto por S2 y S4. Por otro lado, para activar un IGBT, o lo que es lo mismo, que esté conduciendo o en estado “ON”, será necesario que su señal de base esté a nivel alto “1”, mientras que para desactivarlo y que esté cortado o en estado “OFF”, la señal de control de la base deberá ser “0”.

A modo de ejemplo y resumen, en la Tabla 1 se muestran los posibles valores de las señales de control de la primera rama del inversor, junto con las tensiones y el estado  $S_A$  resultante. En ella, se han remarcado los estados principales asociados a cada posible tensión de salida para esta rama concreta del inversor y en los que podrá estar en funcionamiento durante su operación. Cuando la salida de la rama es  $+V_{DC}/2$ , se dirá que  $S_A$  está en el estado de salida positiva y se identificará por “P”; si la salida tiene una tensión  $-V_{DC}/2$  estará en el estado de salida negativa y se identificará con “N”, y por último cuando sea nula se identificará con el estado “0”. La misma tabla es aplicable al resto de ramas, particularizada para sus propios IGBT.

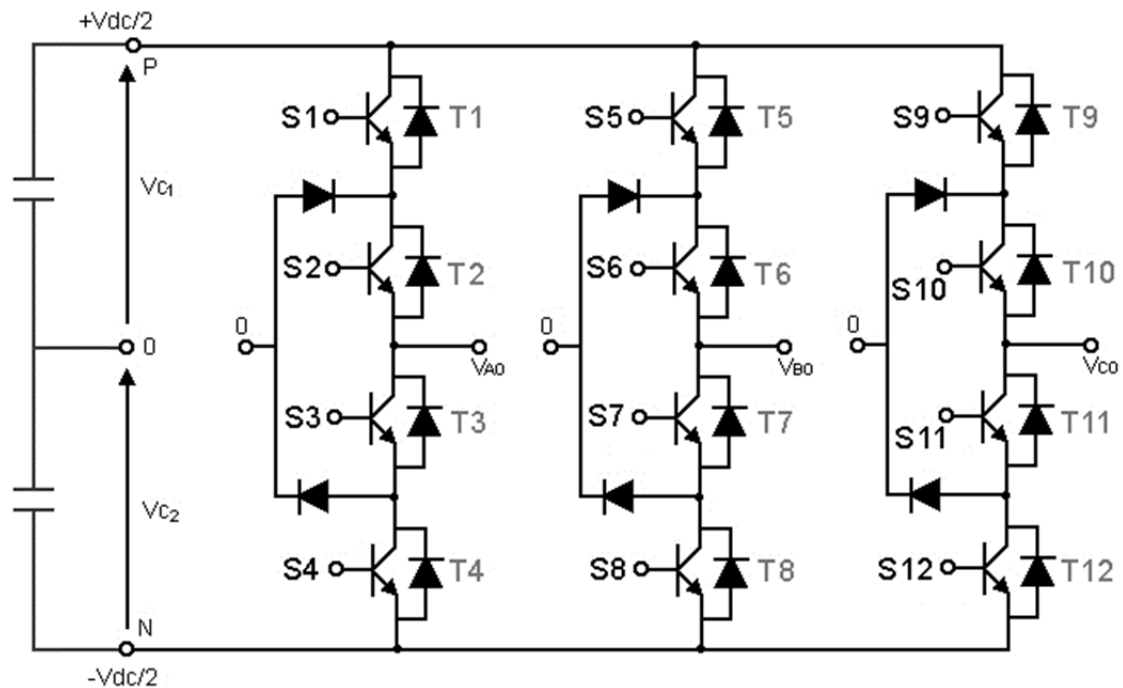


Figura 7. Circuito interno de un inversor trifásico de 3 niveles, 3L-NPC.

En la Tabla 1 también se puede apreciar que existen algunas combinaciones que dan los mismos resultados de tensión, es decir, son redundantes y, por tanto, no se tienen en cuenta; otros que no conectan la salida a ningún nivel de tensión, y otros que implican estados no permitidos que pueden dañar al inversor, identificándose dos casos principales:

- Cuando se producen cortocircuitos, bien entre los puntos “P” y “N”, entre “P” y “0” o entre “N” y “0”. Esto implicaría un aumento de las corrientes que circulan por todos o algunos IGBT de la rama, y la posible destrucción de los mismos.
- Cuando se superen las tensiones máximas permitidas entre el colector y emisor de los IGBT. Los IGBT pueden soportar una tensión máxima determinada, y normalmente se escogen para que toleren un cierto margen por encima de la  $V_{DC}/2$  máxima que se podrá tener en el sistema, y que se espera que puedan llegar a tener durante el funcionamiento normal. Si en algún estado de conmutación se superan estos  $V_{DC}/2$  voltios, por ejemplo con  $V_{DC}$ , se considera que está en riesgo el IGBT y los condensadores que conforman el Bus-DC.

Estas dos condiciones serán muy relevantes a la hora de implementar las protecciones hardware del inversor, y cuando se aplican las señales de actuación sobre los IGBT y por tanto se elige un estado del inversor. Debe asegurarse que una rama no pase

nunca por un estado no permitido. Estos estados solo se darían bajo una configuración errónea del inversor haciendo que no funcionen los semi-puentes como es debido o configurando las transiciones erróneamente.

Tabla 1. Estados de conmutación de la primera rama de un inversor 3L-NPC

S1	S2	S3	S4	S <sub>A</sub> (estado)	Salida V <sub>A0</sub>
0	0	0	0	Desconectado	Alta impedancia
0	0	0	1	Desconectado	Alta impedancia
0	0	1	0	Desconectado	Alta impedancia
0	0	1	1	(N)	$-V_{DC}/2$
0	1	0	0	Desconectado	Alta impedancia
0	1	0	1	Desconectado	Alta impedancia
0	1	1	0	(0)	0
0	1	1	1	No permitido	C.C. entre N y 0, V <sub>DC</sub> en S1
1	0	0	0	Desconectado	Alta impedancia
1	0	0	1	(0) - repetido	0
1	0	1	0	Desconectado	Alta impedancia
1	0	1	1	No permitido	V <sub>DC</sub> en S2
1	1	0	0	(P)	$+V_{DC}/2$
1	1	0	1	No permitido	V <sub>DC</sub> en S3
1	1	1	0	No permitido	C.C. entre P y 0, V <sub>DC</sub> en S4
1	1	1	1	No permitido	C.C. entre P y N

Como se verá posteriormente, los IGBT de los extremos de cada rama (T1, T4, T5, T8, T9 y T12), cada uno perteneciente a un semi-puente, tienen una especial importancia en la secuencia de configuración de los IGBT. Además, debido a la configuración en semi-puente, las señales de control de los IGBT interiores pueden generarse como la inversa de los exteriores, por tanto, para simplificar el análisis, se pueden manejar solamente los valores de los exteriores. Así, solo será necesario generar o tener en cuenta 6 señales para modelar el estado de conmutación del inversor, en vez de las 12 totales que estrictamente son necesarias.

El funcionamiento simplificado de los IGBT de una rama, es por tanto el de un conmutador, de tal manera que las salidas V<sub>A0</sub>, V<sub>B0</sub> y V<sub>C0</sub> puedan conectarse y tomar los 3 valores o niveles de tensiones posibles: al punto positivo “P” con valor  $+V_{DC}/2$ , al negativo “N” con valor  $-V_{DC}/2$ , o al punto central “0” de tensión nula. En la Figura 8 se

muestra en esquema funcional simplificado de un inversor 3L-NPC en el que cada rama funciona como un conmutador que conecta cada salida con estas 3 posiciones.




Figura 8. Esquema de funcionamiento simplificado de un inversor 3L-NPC.

De esta manera, la Tabla 2 recoge los 27 posibles estados en los que puede funcionar el inversor 3L-NPC completo, mostrando el valor de tensión de cada una de las salidas de cada rama, y obviando las señales digitales de control de los IGBT internos opuestos en los *half-bridges* de cada rama como se ha comentado anteriormente. Como se puede ver, cada uno de los estados define un vector de salida único identificado por  $S_A$ ,  $S_B$ , y  $S_C$  o bien  $V_{A0}$ ,  $V_{B0}$  y  $V_{C0}$ .

Tabla 2. Definición de los diferentes estados de conmutación de un inversor 3L-NPC en base a las señales de control de los IGBT.

S1	S4	S5	S8	S9	S12	$S_A$	$S_B$	$S_C$	Estado del inversor (j)	$V_{A0}$	$V_{B0}$	$V_{C0}$
0	0	0	0	0	0	(O)	(O)	(O)	0	0	0	0
0	1	0	1	0	1	(N)	(N)	(N)	1	$-V_{DC}/2$	$-V_{DC}/2$	$-V_{DC}/2$
1	0	1	0	1	0	(P)	(P)	(P)	2	$+V_{DC}/2$	$+V_{DC}/2$	$+V_{DC}/2$
1	0	0	0	0	0	(P)	(O)	(O)	3	$+V_{DC}/2$	0	0
0	0	0	1	0	1	(O)	(N)	(N)	4	0	$-V_{DC}/2$	$-V_{DC}/2$
1	0	1	0	0	0	(P)	(P)	(O)	5	$+V_{DC}/2$	$+V_{DC}/2$	0
0	0	0	0	0	1	(O)	(O)	(N)	6	0	0	$-V_{DC}/2$
0	0	1	0	0	0	(O)	(P)	(O)	7	0	$+V_{DC}/2$	0
0	1	0	0	0	1	(N)	(O)	(N)	8	$-V_{DC}/2$	0	$-V_{DC}/2$
0	0	1	0	1	0	(O)	(P)	(P)	9	0	$+V_{DC}/2$	$+V_{DC}/2$
0	1	0	0	0	0	(N)	(O)	(O)	10	$-V_{DC}/2$	0	0



S1	S4	S5	S8	S9	S12	S <sub>A</sub>	S <sub>B</sub>	S <sub>C</sub>	Estado del inversor (j)	V <sub>A0</sub>	V <sub>B0</sub>	V <sub>C0</sub>
0	0	0	0	1	0	(0)	(0)	(P)	11	0	0	+V <sub>DC</sub> /2
0	1	0	1	0	0	(N)	(N)	(0)	12	-V <sub>DC</sub> /2	-V <sub>DC</sub> /2	0
1	0	0	0	1	0	(P)	(0)	(P)	13	+V <sub>DC</sub> /2	0	+V <sub>DC</sub> /2
0	0	0	1	0	0	(0)	(N)	(0)	14	0	-V <sub>DC</sub> /2	0
1	0	0	1	0	1	(P)	(N)	(N)	15	+V <sub>DC</sub> /2	-V <sub>DC</sub> /2	-V <sub>DC</sub> /2
1	0	0	0	0	1	(P)	(0)	(N)	16	+V <sub>DC</sub> /2	0	-V <sub>DC</sub> /2
1	0	1	0	0	1	(P)	(P)	(N)	17	+V <sub>DC</sub> /2	+V <sub>DC</sub> /2	-V <sub>DC</sub> /2
0	0	1	0	0	1	(0)	(P)	(N)	18	0	+V <sub>DC</sub> /2	-V <sub>DC</sub> /2
0	1	1	0	0	1	(N)	(P)	(N)	19	-V <sub>DC</sub> /2	+V <sub>DC</sub> /2	-V <sub>DC</sub> /2
0	1	1	0	0	0	(N)	(P)	(0)	20	-V <sub>DC</sub> /2	+V <sub>DC</sub> /2	0
0	1	1	0	1	0	(N)	(P)	(P)	21	-V <sub>DC</sub> /2	+V <sub>DC</sub> /2	+V <sub>DC</sub> /2
0	1	0	0	1	0	(N)	(0)	(P)	22	-V <sub>DC</sub> /2	0	+V <sub>DC</sub> /2
0	1	0	1	1	0	(N)	(N)	(P)	23	-V <sub>DC</sub> /2	-V <sub>DC</sub> /2	+V <sub>DC</sub> /2
0	0	0	1	1	0	(0)	(N)	(P)	24	0	-V <sub>DC</sub> /2	+V <sub>DC</sub> /2
1	0	0	1	1	0	(P)	(N)	(P)	25	+V <sub>DC</sub> /2	-V <sub>DC</sub> /2	+V <sub>DC</sub> /2
1	0	0	1	0	0	(P)	(N)	(0)	26	+V <sub>DC</sub> /2	-V <sub>DC</sub> /2	0

### 2.2.2 Control de las Señales de Activación de los IGBT

Según lo que se ha comentado en el apartado anterior, cuando se configura al inversor para que esté en un determinado estado, debe asegurarse que las transiciones ON↔OFF que se apliquen a los IGBT, no les hagan pasar por estados no permitidos para el inversor. Para asegurar el buen funcionamiento del inversor, en algunas transiciones se deben aplicar tiempos muertos o retrasos impuestos en la activación o desactivación de las señales de control de los IGBT. Según las características del inversor que se utiliza, se tiene que elegir un tiempo muerto determinado (59) (60). Para este trabajo, se considerarán tiempos muertos de 5μs.

Para que se produzcan transiciones correctas sin pasar por estados no permitidos, se consideran dos reglas principales que rigen la secuencia de conmutación:

- 1) En una transición entre dos estados, primeramente, se cortarán los IGBT que tengan que hacerlo, y solo después se activarán aquellos que corresponda. En la práctica, esto implica que primero se permitirán los flancos de bajada (pasos de ON a OFF) de las señales de control de los IGBT, y posteriormente, con un tiempo muerto de 5 μs los flancos de subida (pasos de OFF a ON).

Configurando primero los IGBT que tenga que desconectarse, aseguramos que las conexiones que provoquen cortocircuitos no se produzcan.

- 2) En caso que varios IGBT de una misma rama tengan que realizar un cambio de estado de ON a OFF (flancos de bajada), primero se realizarán aquellos cambios que afecten a los IGBT exteriores y luego los de los interiores. Esto se hace debido a que los transistores exteriores son los que conectan las tensiones  $+V_{DC}/2$  o  $-V_{DC}/2$  y es crítico que estas sean las primeras que se aíslan para no crear caminos de corrientes no deseados.

Siguiendo estas dos reglas, la Tabla 3 muestra las transiciones efectuadas en las señales de control de los IGBT en cada uno de los posibles cambios de estado para la primera rama de un inversor 3L-NPC (pudiéndose extrapolar el comportamiento a las demás) asegurando que nunca se incumplen las condiciones anteriormente descritas.

Tabla 3. Secuencias de conmutación correctas de las señales de control de los IGBT para asegurar un buen funcionamiento, para el caso específico de la primera rama de un inversor 3L-NPC.

Paso	S1	S2	S3	S4	Efecto	Estado
Secuencia de conmutación P → 0						
0	1	1	0	0	-	P
1	0	1	0	0	S1 a OFF	Intermedio
2	0	1	1	0	S3 a ON tras 5μs	0
Secuencia de conmutación 0 → P						
0	0	1	1	0	-	0
1	0	1	0	0	S3 a OFF	Intermedio
2	1	1	0	0	S1 a ON tras 5μs	P
Secuencia de conmutación N → 0						
0	0	0	1	1	-	N
1	0	0	1	0	S4 a OFF	Intermedio
2	0	1	1	0	S2 a ON tras 5μs	0
Secuencia de conmutación 0 → N						
0	0	1	1	0	-	0
1	0	0	1	0	S2 a OFF	Intermedio
2	0	0	1	1	S4 a ON tras 5μs	N
Secuencia de conmutación P → N						
0	1	1	0	0	-	P
1	0	1	0	0	S1 a OFF	Intermedio
2	0	0	0	0	S2 a OFF	Intermedio
3	0	0	1	0	S3 a ON tras 5μs	Intermedio

Paso	S1	S2	S3	S4	Efecto	Estado
4	0	0	1	1	S4 a ON tras 5 $\mu$ s	N
Secuencia de conmutación N $\rightarrow$ P						
0	0	0	1	1	-	N
1	0	0	1	0	S4 a OFF	Intermedio
2	0	0	0	0	S3 a OFF	Intermedio
3	0	1	0	0	S2 a ON tras 5 $\mu$ s	Intermedio
4	1	1	0	0	S1 a ON tras 5 $\mu$ s	P

La información descrita anteriormente, se puede ver gráficamente en la Figura 9, donde se muestran todas las posibles transiciones de estados de una rama del inversor.

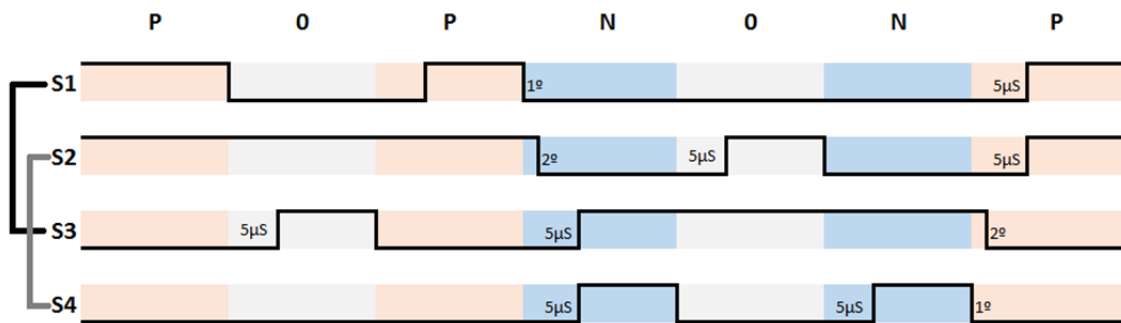


Figura 9. Secuencias correctas de activación y desactivación de los IGBT durante las transiciones de estados de la primera rama de un inversor 3L-NPC.

### 2.2.3 Transformación al Plano $\alpha\beta$

Comúnmente, cuando se trabaja con señales trifásicas, que se denominan como “*abc*”, y teniendo en cuenta las relaciones existentes entre estas tensiones, se puede simplificar el funcionamiento del sistema, mediante una transformación a un plano de dos dimensiones, donde el sistema trifásico se corresponde con un fasor con parte real o “alfa” y parte imaginaria o “beta”, conociéndose este proceso como Transformación al Plano  $\alpha\beta$ . Con ello, se trabaja y realizan los cálculos sobre 2 componentes en vez de tres, resultando así cálculos más simples.

La transformación del plano trifásico al plano  $\alpha\beta$  queda definida mediante las siguientes expresiones:

$$V_{\alpha} = \sqrt{\frac{2}{3}} V_{A0} - \sqrt{\frac{1}{6}} (V_{B0} + V_{C0}) \quad [2]$$

$$V_{\beta} = \frac{\sqrt{2}}{2} (V_{B0} - V_{C0}) \quad [3]$$

Y si transformamos los valores de tensiones de cada uno de los estados del inversor vistos en la Tabla 2, al plano  $\alpha\beta$ , dichos vectores quedan definidos según lo que se muestra en la Tabla 4.

Tabla 4. Definición de los estados de conmutación en el plano  $\alpha\beta$  de un inversor 3L-NPC.

Estado Conmut.	$V_{A0}$	$V_{B0}$	$V_{C0}$	Vector tensión	$V_{\alpha}$	$V_{\beta}$
0	0	0	0	$V_0$	0	0
1	$-V_{DC}/2$	$-V_{DC}/2$	$-V_{DC}/2$			
2	$+V_{DC}/2$	$+V_{DC}/2$	$+V_{DC}/2$			
3	$+V_{DC}/2$	0	0	$V_1$	$+\sqrt{1/6}V_{DC}$	0
4	0	$-V_{DC}/2$	$-V_{DC}/2$			
5	$+V_{DC}/2$	$+V_{DC}/2$	0	$V_2$	$+\sqrt{1/24}V_{DC}$	$+\sqrt{1/8}V_{DC}$
6	0	0	$-V_{DC}/2$			
7	0	$+V_{DC}/2$	0	$V_3$	$-\sqrt{1/24}V_{DC}$	$+\sqrt{1/8}V_{DC}$
8	$-V_{DC}/2$	0	$-V_{DC}/2$			
9	0	$+V_{DC}/2$	$+V_{DC}/2$	$V_4$	$-\sqrt{1/6}V_{DC}$	0
10	$-V_{DC}/2$	0	0			
11	0	0	$+V_{DC}/2$	$V_5$	$-\sqrt{1/24}V_{DC}$	$-\sqrt{1/8}V_{DC}$
12	$-V_{DC}/2$	$-V_{DC}/2$	0			
13	$+V_{DC}/2$	0	$+V_{DC}/2$	$V_6$	$+\sqrt{1/24}V_{DC}$	$-\sqrt{1/8}V_{DC}$
14	0	$-V_{DC}/2$	0			
15	$+V_{DC}/2$	$-V_{DC}/2$	$-V_{DC}/2$	$V_7$	$+\sqrt{2/3}V_{DC}$	0
16	$+V_{DC}/2$	0	$-V_{DC}/2$	$V_8$	$+\sqrt{3/8}V_{DC}$	$+\sqrt{1/8}V_{DC}$
17	$+V_{DC}/2$	$+V_{DC}/2$	$-V_{DC}/2$	$V_9$	$+\sqrt{1/6}V_{DC}$	$+\sqrt{1/2}V_{DC}$
18	0	$+V_{DC}/2$	$-V_{DC}/2$	$V_{10}$	0	$+\sqrt{1/2}V_{DC}$
19	$-V_{DC}/2$	$+V_{DC}/2$	$-V_{DC}/2$	$V_{11}$	$-\sqrt{1/6}V_{DC}$	$+\sqrt{1/2}V_{DC}$
20	$-V_{DC}/2$	$+V_{DC}/2$	0	$V_{12}$	$-\sqrt{3/8}V_{DC}$	$+\sqrt{1/8}V_{DC}$
21	$-V_{DC}/2$	$+V_{DC}/2$	$+V_{DC}/2$	$V_{13}$	$-\sqrt{2/3}V_{DC}$	0
22	$-V_{DC}/2$	0	$+V_{DC}/2$	$V_{14}$	$-\sqrt{3/8}V_{DC}$	$-\sqrt{1/8}V_{DC}$

Estado Conmut.	$V_{A0}$	$V_{B0}$	$V_{C0}$	Vector tensión	$V_\alpha$	$V_\beta$
23	$-V_{DC}/2$	$-V_{DC}/2$	$+V_{DC}/2$	$V_{15}$	$-\sqrt{1/6}V_{DC}$	$-\sqrt{1/2}V_{DC}$
24	0	$-V_{DC}/2$	$+V_{DC}/2$	$V_{16}$	0	$-\sqrt{1/2}V_{DC}$
25	$+V_{DC}/2$	$-V_{DC}/2$	$+V_{DC}/2$	$V_{17}$	$+\sqrt{1/6}V_{DC}$	$-\sqrt{1/2}V_{DC}$
26	$+V_{DC}/2$	$-V_{DC}/2$	0	$V_{18}$	$+\sqrt{3/8}V_{DC}$	$-\sqrt{1/8}V_{DC}$

Como se puede ver en la Tabla 4, al realizar la transformación al plano  $\alpha\beta$ , existen 19 diferentes vectores de tensión posibles en el inversor, cada uno de ellos relacionado directamente con uno o varios estados de conmutación en el plano trifásico. Esta reducción en el número de vectores distintos de salida, se debe a que existen algunos estados que producen los mismos valores de tensión  $V_\alpha$  y  $V_\beta$ . Sin embargo, como se verá posteriormente, no solo se debe tener en cuenta el vector de tensiones en el Control Predictivo, sino que existen otros factores como la frecuencia de conmutación o el desequilibrio del Bus-DC, que dependen del estado de conmutación, por lo que siempre habrá que evaluar los 27 estados posibles.

Debido a la simplificación que se consigue con esta transformación, y que trabajar en ambos planos es totalmente equivalente, el algoritmo de Control Predictivo se diseñará en el plano  $\alpha\beta$ . Con esto, en vez de tener que predecir 3 corrientes diferentes ( $i_a$ ,  $i_b$  e  $i_c$ ) para elegir el estado óptimo en el que se deba configurar el inversor, tan solo se tendrán que predecir 2 corrientes ( $i_\alpha$  e  $i_\beta$ ), reduciéndose por tanto en un tercio el número de operaciones que se deben realizar.

La Figura 10 muestra la constelación de posibles estados en los que puede configurarse un inversor 3L-NPC trabajando en el plano  $\alpha\beta$ , y sus vectores de tensión asociados. Estando en el estado actual “i” con un vector asociado de tensión  $V_i$ , el algoritmo de Control Predictivo tendrá que evaluar para el siguiente ciclo de control, el futuro estado “j” en el que se deberá configurar el inversor, pudiendo ser a priori cualquiera de los 27 (incluyendo el actual).

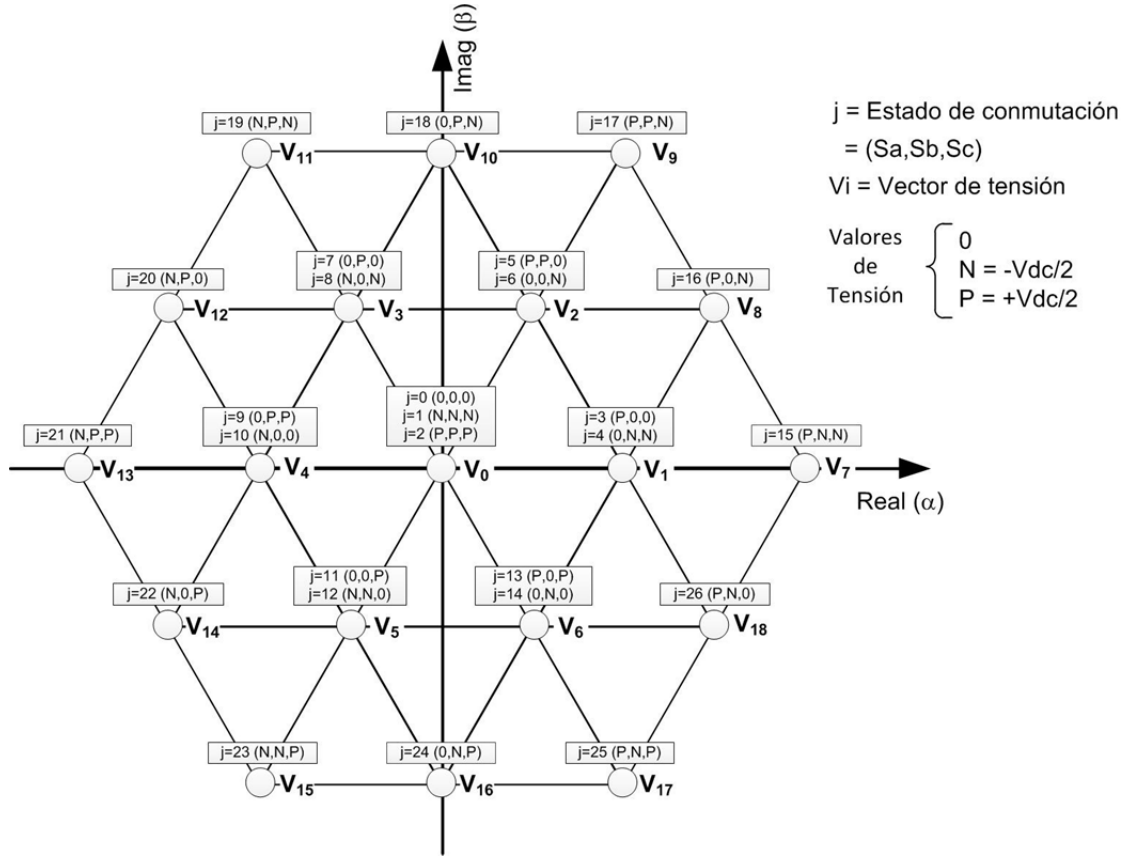


Figura 10. Representación en el plano  $\alpha\beta$  de los vectores de tensión correspondientes a cada estado de conmutación de un inversor 3L-NPC en el plano  $\alpha\beta$ .

## 2.2.4 Modelo Predictivo de la Corriente de Salida

Para predecir el comportamiento del sistema conjunto, se emplea un modelo matemático, derivado directamente de aplicar las ecuaciones de las mallas eléctricas que resultan, según el tipo de filtro que se use para conectar el inversor a red. El modelo de base para esta tesis contiene un filtro de conexión a red compuesto por una resistencia y una bobina, o filtro RL, como el que se muestra en la Figura 11.

Si se tiene solo en cuenta una de las mallas de salida, la relación matemática que existe entre las diferentes variables de la misma, queda definida según la Ley de Kirchoff de la propia malla por:

$$v(t) = L \frac{di(t)}{dt} + Ri(t) + e(t) \quad [4]$$

Debido a que las señales implicadas normalmente serán de 50Hz, y que la frecuencia de muestreo de dichas señales es mucho mayor (del orden de kHz), se puede aproximar la derivada de la corriente respecto al tiempo como la tasa de variación media o pendiente según [ 5].

$$\frac{di(t)}{dt} \approx \frac{i(k) - i(k-1)}{T_s} \quad [ 5]$$

Con esta aproximación, la ecuación descrita en [ 4] queda como:

$$v(t) \approx L \frac{i(k) - i(k-1)}{T_s} + Ri(t) + e(t) \quad [ 6]$$




Figura 11. Circuito y modelo de la carga a la salida del inversor.

Y despejando de [ 6] el valor de corriente  $i(k)$ , se obtiene la ecuación que describe de forma discreta la corriente que circula por la malla como:

$$i(k) \approx \frac{T_s}{RT_s + L} \left[ \frac{L}{T_s} i(k-1) + v(k) - e(k) \right] \quad [ 7]$$

Realizando un cambio hacia un instante inmediatamente superior en [ 7], es decir, sustituyendo el instante  $k$  por  $k+1$ , se obtienen las ecuaciones principales en el plano  $\alpha\beta$ , del modelo predictivo de la corriente que circula por una rama.

$$i_\alpha(k+1) \approx \frac{T_s}{RT_s + L} \left[ \frac{L}{T_s} i_\alpha(k) + v_\alpha(k+1) - e_\alpha(k+1) \right] \quad [ 8]$$

$$i_\beta(k+1) \approx \frac{T_s}{RT_s + L} \left[ \frac{L}{T_s} i_\beta(k) + v_\beta(k+1) - e_\beta(k+1) \right] \quad [ 9]$$

Estas últimas expresiones, constituyen el modelo matemático para poder predecir los valores futuros de corrientes, que dependerá de:

1. La muestra de corriente actual  $i(k)$ .
2. El valor futuro de la tensión de salida del inversor de la rama en concreto,  $v(k+1)$ , el cual depende directamente del estado de conmutación en el que se configure el inversor y que se puede modelar según lo visto en el punto 2.2.1.
3. El valor de  $e(k+1)$ , que puede extrapolarse a partir de muestras anteriores como se verá más adelante.

Todos los demás parámetros son parámetros del sistema:  $T_s$ ,  $R$  y  $L$ . Como se deduce de lo anterior, el objetivo principal del Control Predictivo consistirá en obtener los valores de  $i_\alpha(k+1)$  y de  $i_\beta(k+1)$  para cada posible estado futuro  $j$ , lo que dependerá de la variable  $v(k+1)$ , a partir de ahora por tanto  $v(j,k+1)$ . Luego, el conjunto de posibles corrientes que el Control Predictivo tendrá que evaluar, estará descrito por:

$$i_\alpha(j, k+1) \approx \frac{T_s}{RT_s + L} \left[ \frac{L}{T_s} i_\alpha(k) + v_\alpha(j, k+1) - e_\alpha(k+1) \right] \quad \forall j = 0, \dots, 26 \quad [10]$$

$$i_\beta(j, k+1) \approx \frac{T_s}{RT_s + L} \left[ \frac{L}{T_s} i_\beta(k) + v_\beta(j, k+1) - e_\beta(k+1) \right] \quad \forall j = 0, \dots, 26 \quad [11]$$

Separando términos en [10] y [11], las predicciones de las corrientes del sistema se pueden finalmente expresar como:

$$i_\alpha(j, k+1) \approx \frac{L}{RT_s + L} i_\alpha(k) + \frac{T_s}{RT_s + L} v_\alpha(j, k+1) - \frac{T_s}{RT_s + L} e_\alpha(k+1) \quad \forall j = 0, \dots, 26 \quad [12]$$

$$i_\beta(j, k+1) \approx \frac{L}{RT_s + L} i_\beta(k) + \frac{T_s}{RT_s + L} v_\beta(j, k+1) - \frac{T_s}{RT_s + L} e_\beta(k+1) \quad \forall j = 0, \dots, 26 \quad [13]$$

Donde los términos  $\frac{T_s}{RT_s + L} v_{\alpha\beta}(j, k+1)$  solo dependen del futuro estado  $j$ , y pueden ser considerados como elementos conocidos, debido a que los valores de  $T_s$ ,  $R$  y  $L$  se consideran fijos o de variación mínima desde el punto de vista del control, y los propios



valores de tensión son conocidos a priori para cada uno de los estados del inversor ( $v_{\alpha\beta}(j)$ ). Por tanto, pueden ser obtenidos directamente mediante una tabla predefinida de valores. Gracias a ello, en la implementación de la predicción no es preciso calcular estos valores, que estarán pre-calculados con anterioridad, ya que no dependen de muestras de señales de corrientes o tensiones.

### 2.2.5 Modelo Predictivo de la tensión de Red

De las expresiones [ 12] y [ 13], se advierte que resulta necesario calcular la predicción de las tensiones de la red eléctrica  $e_\alpha(k+1)$  y  $e_\beta(k+1)$ . Para realizar esta predicción, se ha optado por usar una extrapolación de Lagrange de segundo orden definida por [ 14] y [ 15], que resultan más que suficiente para señales de variación lenta (61) (como son las tensiones de red de 50Hz), con altas frecuencias de muestreo (del orden de kHz).

$$e_\alpha(k+1) = 3e_\alpha(k) - 3e_\alpha(k-1) + e_\alpha(k-2) \quad [ 14]$$

$$e_\beta(k+1) = 3e_\beta(k) - 3e_\beta(k-1) + e_\beta(k-2) \quad [ 15]$$

Como se deduce de [ 14] y [ 15], resulta indispensable obtener las muestras de las tensiones de red  $e_a(t)$ ,  $e_b(t)$ , y  $e_c(t)$ , para posteriormente realizar una conversión al plano  $\alpha\beta$  y obtener  $e_\alpha(t)$  y  $e_\beta(t)$  usando [ 2] y [ 3]. Además, se necesita una memoria de hasta 2 muestras anteriores de las señales, o dicho de otro modo, la extrapolación tendrá una latencia de dos ciclos de trabajo, aunque solo será relevante al arrancar el controlador y es un error totalmente asumible como se demostrará en el funcionamiento del sistema.

Por otra parte, cuando se implementan sistemas con tiempo de ejecución crítico y recursos limitados, el orden de las operaciones y el tipo de las mismas, influyen en gran medida en el cumplimiento de las restricciones, tanto en tiempo como en área de silicio. Así, las expresiones [ 14] y [ 15] que suponen la realización de 4 multiplicaciones, 2 restas y 2 sumas, se pueden expresar como [ 16] y [ 17] para reducir en 2 el número de multiplicaciones, operación que consume grandes recursos en un diseño.

$$e_{\alpha}(k+1) = 3(e_{\alpha}(k) - e_{\alpha}(k-1)) + e_{\alpha}(k-2) \quad [16]$$

$$e_{\beta}(k+1) = 3(e_{\beta}(k) - e_{\beta}(k-1)) + e_{\beta}(k-2) \quad [17]$$

### 2.2.6 Función de coste

A partir del modelo de corriente que permite predecir la corriente de salida del inversor en función del estado en que se le configure, se necesita proponer una función de optimización que tenga en cuenta diversos objetivos de control, para determinar cuál debería ser el próximo estado del convertidor. Para ello se evalúa una función de coste, que, en su versión más simple, calcula el error o desviación con respecto a las consignas de las corrientes, seleccionando aquel estado que minimice dicha desviación como estado óptimo futuro. Por tanto, se propone la siguiente función de coste para evaluar las distintas opciones de actuación sobre el inversor:

$$g(j) = |i_{\alpha}^*(k) - i_{\alpha}(j, k+1)| + |i_{\beta}^*(k) - i_{\beta}(j, k+1)| \quad \forall j = 0, \dots, 26 \quad [18]$$

Donde se definen los siguientes términos:

- $i_{\alpha}^*(k)$ : corriente de referencia en la componente  $\alpha$  en el instante de observación  $k$ .
- $i_{\beta}^*(k)$ : corriente de referencia en la componente  $\beta$  en el instante de observación  $k$ .
- $i_{\alpha}(j, k+1)$ : predicción de corriente en la componente  $\alpha$  para el siguiente instante  $k+1$  aplicando el estado  $j$  al inversor.
- $i_{\beta}(j, k+1)$ : predicción de corriente en la componente  $\beta$  para el siguiente instante  $k+1$  aplicando el estado  $j$  al inversor.

Como se comentó en el capítulo introductorio, esta función de coste se puede ampliar para incluir otros objetivos o restricciones de control que puedan ser necesarios para el buen funcionamiento del sistema, pudiéndose definir una función de coste genérica, siempre incluyendo al menos el *tracking*, como:

$$g(j) = |i_{\alpha}^*(k) - i_{\alpha}(j, k+1)| + |i_{\beta}^*(k) - i_{\beta}(j, k+1)| + \lambda \cdot \text{Param1} + \dots + \mu \cdot \text{ParamN} \quad [19]$$

Siendo el conjunto  $[\lambda, \dots, \mu]$ , los denominados factores de peso o de ponderación de cada uno de los objetivos de control considerados.

En este trabajo, se consideran, además del *tracking*, dos objetivos de control que se incluirán en la función de coste:

- El desequilibrio del Bus-DC, indispensable para que los valores de  $+V_{DC}/2$  y los de  $-V_{DC}/2$  sean lo más parecidos posibles, ya que, de no serlos, las tensiones de salidas  $V_{A0}$ ,  $V_{B0}$  y  $V_{C0}$  perderán simetría.
- La frecuencia de conmutación de los IGBT, para no permitir que los IGBT conmuten a frecuencias altas, y por tanto introduzcan ruidos de armónicos de alta frecuencia o empeoren la eficiencia de la conversión.

Así pues, para el caso de estudio, se define la función de coste específica como:

$$g(j) = |i_{\alpha}^*(k) - i_{\alpha}(j, k + 1)| + |i_{\beta}^*(k) - i_{\beta}(j, k + 1)| + \lambda_{DC} \cdot |\Delta V_c(j, k + 1)| + \lambda_{SW} \cdot Nc(i, j) \quad [20]$$

Donde se definen los siguientes términos, además de los anteriormente expuestos en la expresión [18]:

- $\lambda_{DC}$ : factor de peso del control del desequilibrio del Bus-DC.
- $|\Delta V_c(j, k + 1)|$ : predicción del desequilibrio en valor absoluto que se producirá entre las tensiones del Bus-DC al configurar el inversor en el estado “j”.
- $\lambda_{SW}$ : factor de peso del control de la frecuencia de conmutación de los IGBT.
- $Nc(i, j)$ : número de conmutaciones que se producirán al realizarse la posible transición futura del estado actual  $i$ , al estado próximo  $j$ .

### 2.2.7 Generación de la Corriente de Referencia

Atendiendo a la función de coste propuesta, se hacen necesarias las referencias de corriente  $i_{\alpha}^*$  e  $i_{\beta}^*$ , dado que el control de corriente se ha diseñado para operar en el dominio  $\alpha\beta$ .

La obtención de las corrientes de referencia requiere, primeramente, la definición de las consignas de potencia para un convertidor 3L-NPC en un caso de aplicación real como el mostrado en el capítulo introductorio, en el que el sistema se utiliza para inyectar potencia a la red eléctrica a partir de un aerogenerador. La potencia aparente

total dependerá de cierto nivel de potencia activa, que denominaremos  $P$ , y cierta potencia reactiva que denominaremos  $Q$ .

La componente de potencia activa  $P$  suministrada a la red eléctrica, se define comúnmente como aquella potencia que es aprovechable por las cargas que estén conectadas a la red. Es la potencia asociada a una corriente que esté en fase con la tensión de red, y por tanto es disipable o tiene un carácter resistivo, por lo que se puede transformar en calor o trabajo. Esta potencia se mide en kW. Por otro lado, la componente de potencia reactiva  $Q$ , es una potencia no aprovechable por los equipos que se conecten a la red eléctrica, sino que representa la energía que se almacena en los elementos inductivos o capacitivos del circuito, y está asociada a una corriente que se encuentra desfasada respecto a la fuerza electromotriz o tensión de red. La potencia  $Q$  se mide normalmente en kVAR. Además, la componente reactiva puede considerarse de efecto capacitivo cuando el desfase respecto a la tensión de red es positivo, o bien de efecto inductivo cuando el desfase es negativo. La potencia reactiva  $Q$  no se disipa en las cargas finales conectadas a la red de consumo, sino que lo hace en los conductores, impedancias o elementos de los filtros (en general cargas complejas).

La suma vectorial de la potencia activa  $P$  más la potencia reactiva  $Q$ , define lo que se denomina como potencia aparente  $S$ , la cual representa la potencia total que es capaz de suministrar el convertidor sobre una carga compleja  $Z$ . Esta magnitud se mide en kVA (kilo Voltio-Amperio). De forma fasorial, la componente en fase con la tensión de red  $P$  es la componente real de  $S$ , y la otra con un desfase de  $90^\circ$ ,  $Q$ , representa la componente imaginaria del vector. La Figura 12 muestra gráficamente esta relación, donde se define, además, el ángulo  $\varphi$  como el desfase que existirá entre  $S$  y la tensión de red (en fase con  $P$ ). Con todo ello, la ecuación que define el módulo o magnitud de  $S$  sería:

$$S^2 = P^2 + Q^2 \rightarrow S = \sqrt{P^2 + Q^2} \quad [21]$$




Figura 12. Representación fasorial de la potencia aparente  $S$  como suma de la componente en fase o potencia activa  $P$ , y la componente reactiva  $Q$ .

A partir del ángulo  $\varphi$ , se define el factor de potencia como:

$$\text{Factor de Potencia} = \cos \varphi \quad [22]$$

el cual ayuda a indicar de manera rápida, la relación existente entre potencia activa  $P$  y potencia reactiva  $Q$  en un circuito. Así por ejemplo un factor de potencia unidad ( $\cos(\varphi)=1$ ), indicaría que toda la potencia aplicada a un circuito es potencia activa  $P$ , y aprovechable al consumo. Esto indicaría además que no existe energía almacenada ni en bobinas ni en condensadores ( $Q = 0$ ).

Introduciendo potencia reactiva sin variar la potencia aparente, se puede regular la cantidad de potencia activa que se suministra a la red, sin tener que modificar la amplitud de las corrientes generadas. Por ejemplo, para una potencia aparente fija de 100kVA, se pueden proporcionar 80kW de potencia activa a la red, o bien 100kW, haciendo que la potencia reactiva sea 60 o 0 kVAr respectivamente, y si se supone una tensión de red de 400V, ello implica que en ambos casos la corriente eficaz es fija de 250A. Por todo esto, las consignas principales de un convertidor serán la potencia activa que denotaremos como  $P^*$ , y la potencia reactiva  $Q^*$ .

Una vez establecidas las consignas de potencia del convertidor, se puede encontrar una analogía fasorial entre los vectores y componentes de potencia, con los fasores y componentes de las referencias de corriente  $i_\alpha^*$  e  $i_\beta^*$ . Concretamente  $i_\alpha^*$  representa la componente de corriente real asociada a la potencia activa  $P^*$ , mientras que  $i_\beta^*$  representa la componente de corriente imaginaria asociada a la potencia reactiva  $Q^*$ .

Para mostrar mejor esa relación, recuérdese primeramente que las corrientes en el plano  $\alpha\beta$  resultan de aplicar las transformaciones [2] y [3] a partir de las componentes trifásicas  $abc$ . En un circuito donde solo existe potencia activa ( $\varphi=0$ ,  $\cos(\varphi)=1$ ,  $Q=0$ ), las corrientes de red  $i_a$ ,  $i_b$  e  $i_c$  estarán en fase con las tensiones de red  $e_a$ ,  $e_b$  y  $e_c$ . Esto se traducirá en el plano  $\alpha\beta$  en que el fasor de corriente  $\vec{i} = i_\alpha + i_\beta j$  estará en fase con el fasor de tensión  $\vec{e} = e_\alpha + e_\beta j$ . Por el contrario, si en el circuito coexiste una potencia activa  $P$  con una reactiva  $Q$ , y por tanto existe cierto factor de potencia dependiente de  $\varphi$ , esto implica que existirá un desfase entre fasores de corriente y tensión también de  $\varphi$ . No hay que olvidar tampoco que el fasor tensión de red  $\vec{e} = e_\alpha + e_\beta j$ , está definido por un módulo o amplitud y una fase  $\theta(t)$  dependiente de la frecuencia angular  $\omega(t) = 2\pi \cdot f \cdot t$ , donde la frecuencia es de 50Hz. La Figura 13 muestra gráficamente la relación fasorial descrita entre el fasor tensión y el fasor corriente, así como las componentes  $\alpha\beta$  de los mismos.




Figura 13. Representación de la relación fasorial en el plano  $\alpha\beta$  de las tensiones y corrientes de red.

De todo lo anterior, se deduce que para obtener las referencias de corriente  $i_\alpha^*$  e  $i_\beta^*$ , se necesitan dos términos:

- La relación entre potencia activa  $P^*$  y reactiva  $Q^*$ , o lo que es lo mismo el factor de potencia asociado a  $\varphi$ .
- La fase fundamental de la tensión de red  $\theta(t)$ , para poder a partir de ella, desfazar las corrientes el ángulo  $\varphi$  necesario.

El primer término depende directamente de las consignas  $P^*$  y  $Q^*$  que se deseen para el convertidor y son conocidas. El segundo término se obtiene mediante la detección de fase de la componente fundamental de la tensión de red, empleando para ello un PLL (Phase-Locked Loop).

Para la implementación del mecanismo de sincronización con la red eléctrica, en esta tesis se ha usado un método basado en la aplicación de un Integrador Dual Generalizado de Segundo Orden de Señales en Cuadratura o DSOGI-QSG, seguido de un bloque PLL con Trama de Referencia Síncrona o SRF-PLL basado en un integrador Euler Backward, ambos descritos en (42) o (62). Este modelo de sincronización está basado principalmente en la utilización de un PLL que trabaja utilizando componentes en ejes rotatorios, denominados comúnmente como ejes “ $dq$ ”, obtenidos directamente de las consignas de potencia  $P^*$  y  $Q^*$ , y que además permiten generar las componentes  $\alpha\beta$  cuando se haya obtenido la fase fundamental de la tensión de red  $\theta(t)$ .

En la transformación a ejes rotatorios  $dq$ , se considera que los ejes de referencia real e imaginario, se mueven a la vez que los fasores van rotando. Como los ejes se mueven conjuntamente con los fasores, las componentes de estos sobre estos ejes

son siempre constantes en vez de señales sinusoidales, facilitando y simplificando las operaciones matemáticas y simplificando los bloques. Este tipo de PLL puede sincronizarse bien usando la componente  $d$ , o la componente  $q$  como referencia. En este caso, vamos a considerar una sincronización con la componente  $q$ , por tanto, suponiendo que los ejes rotatorios  $dq$  giren a la vez que el fasor  $\vec{e} = e_\alpha + e_\beta j$  de tensión de red, entonces la componente  $q$  valdrá  $e_q = |\vec{e}|$ , mientras que la  $e_d = 0$ , y estas se mantendrían constantes siempre. De igual manera, cualquier señal que esté en fase con  $\vec{e}$  debería tener la componente  $d$  nula, y esta es precisamente el fundamento operativo del SRF-PLL, lo que se traduce en conocer la información de su fase o  $\theta(t)$ . De igual forma, cualquier señal que no estuviera en fase con  $\vec{e}$ , como por ejemplo la corriente de red, se caracterizaría por una componente  $q$  en fase, y una componente  $d$  ortogonal distinta de cero, ambas constantes y girando a la misma frecuencia angular que el fasor de tensión.

La Figura 14 muestra un ejemplo gráfico de relación entre componentes  $dq$  respecto a las  $\alpha\beta$  para cierta corriente, cuando se considera a la componente  $q$  sincronizada con el fasor de tensión. Como se observa en la figura, los valores de las componentes  $dq$  son constantes en el tiempo.




Figura 14. Ejemplo de relación entre las componentes  $\alpha\beta$  de ejes estacionarios, y las componentes  $dq$  de ejes rotatorios para cierta relación entre fasores de corriente y tensión.

Formalmente, la relación que existe para un fasor determinado entre sus componentes  $dq$  y  $\alpha\beta$ , dependerá directamente del desfase entre ambos ejes de coordenadas, que en este caso debido a la configuración de SRF-PLL será la propia fase fundamental de la tensión de red  $\theta(t)$ :

$$i_\alpha = i_d \cdot \cos(\theta(t)) - i_q \cdot \sin(\theta(t)) \quad [23]$$

$$i_{\beta} = i_d \cdot \sin(\theta(t)) + i_q \cdot \cos(\theta(t)) \quad [24]$$

Por otra parte, existe una dependencia directa de las componentes  $dq$  de corrientes y tensiones, respecto a las componentes de potencia activa  $P$  y reactiva  $Q$ , definida según:

$$P = e_d \cdot i_d + e_q \cdot i_q \quad [25]$$

$$Q = e_q \cdot i_d - e_d \cdot i_q \quad [26]$$

Despejando en las anteriores expresiones las variables  $i_q$  e  $i_d$  en función de las tensiones y las potencias, y particularizando para el caso que estas últimas sean referencias o consignas del sistema, es decir,  $P^*$  y  $Q^*$ , las corrientes de referencias en ejes  $dq$  se obtienen a partir de:

$$i_q^* = \frac{e_q \cdot P^* - e_d \cdot Q^*}{e_d^2 + e_q^2} \quad [27]$$

$$i_d^* = \frac{e_d \cdot P^* + e_q \cdot Q^*}{e_d^2 + e_q^2} \quad [28]$$

Como se ha comentado anteriormente, el SRF-PLL se sincronizará con el fasor de tensión  $\vec{e}$ , haciendo que  $e_d$  tienda a ser nulo, y  $e_q = \overline{|e|}$ , por lo que las anteriores expresiones se pueden aproximar como:

$$i_q^* \approx_{e_d \rightarrow 0} \frac{P^*}{\overline{|e|}} \quad [29]$$



$$i_d^* \approx_{ed \rightarrow 0} \frac{Q^*}{|e|} \quad [30]$$

Sin embargo, esta aproximación solo es válida una vez se realice la sincronización, por lo que debe transcurrir un tiempo que se conoce como tiempo de enganche del PLL. En el FSR-PLL con la configuración explicada, se considera que se ha completado la sincronización cuando  $\mathbf{e} \mathbf{q} = \overline{|\mathbf{e}|}$  cuyo valor para un sistema trifásico estándar es de 400V rms, y  $\mathbf{e}_d = 0$ . Una vez se enganche, las referencias obtenidas serán válidas.

Como el controlador trabaja en componentes  $\alpha\beta$ , si mediante el SRF-PLL se obtiene la fase de red  $\theta(t)$ , usando [29] y [30] en las expresiones [23] y [24], se pueden obtener las referencias de corriente  $i_\alpha^*$  y  $i_\beta^*$ . Estas referencias son las que utilizará el Algoritmo de Control Predictivo en su función de coste.

Aunque la implementación de este método de sincronización se detalla en (62), a continuación se mostrará y describirá el modelo en diagrama de bloques y sus funciones principales.

El esquema de bloques que forman el FSR-PLL, junto con el bloque generador de consignas, se muestra en la Figura 15 y a continuación se comenta brevemente la funcionalidad de cada uno.

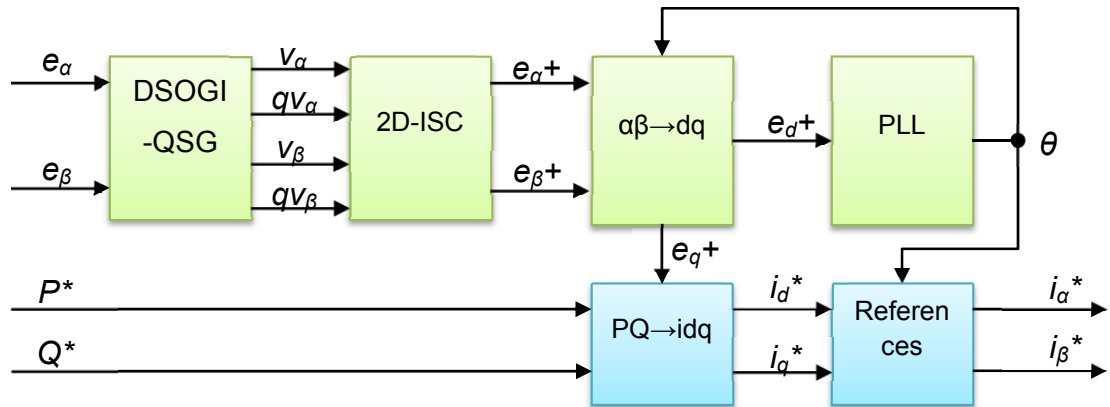


Figura 15. Elementos funcionales incluidos en el bloque de sincronización con la red o SRF-PLL y generación de corrientes de referencia.

DSOGI-QSG: Filtro Dual Generalizado de Segundo Orden que obtiene las componentes en fase y en cuadratura de las tensiones de red en  $\alpha\beta$  con objeto de

obtener después la secuencia positiva de las señales. Un estudio detallado de este filtro se puede encontrar en (62). Su función de transferencia está definida por:

$$H_i(s) = \frac{k_s \cdot \omega_0 \cdot s}{s^2 + k_s \cdot \omega_0 \cdot s + \omega_0^2} \quad [31]$$

$$H_q(s) = \frac{k_s \cdot \omega_0^2}{s^2 + k_s \cdot \omega_0 \cdot s + \omega_0^2}$$

Donde  $k_s$  se define como el factor de amortiguamiento del filtro, y  $\omega_0$  la frecuencia de resonancia o sintonización del mismo, definidos como:

$$k_s = 1; \quad \omega_0 = 2\pi (50\text{Hz}/fs) = 2\pi(50\text{Hz} \cdot Ts) \quad [32]$$

2D-ISC: Selector de Componentes Simétricas Instantáneas 2-Dimensionales, el cual permite separar la secuencia positiva de las componentes  $\alpha\beta$ . La existencia de una secuencia de señales  $\alpha\beta$  positiva, y otra negativa, se debe a que las señales trifásicas  $abc$  pueden presentar desbalanceo que se traduce en dos tipos de secuencias:

- Positiva:  $a$  con  $0^\circ$ ,  $b$  con  $-120^\circ$  y  $c$  con  $+120^\circ$
- Negativa:  $a$  con  $0^\circ$ ,  $b$  con  $+120^\circ$  y  $c$  con  $-120^\circ$

En nuestro caso, la obtención de la secuencia positiva se obtiene a partir de:

$$e_\alpha^+ = v_\alpha - qv_\beta \quad [33]$$

$$e_\beta^+ = qv_\alpha + v_\beta \quad [34]$$

Transformación  $\alpha\beta \rightarrow dq$ : a partir de las ecuaciones [23] y [24], se puede realizar la transformación inversa para pasar de componentes  $\alpha\beta$  a  $dq$ , quedando:

$$e_d^+ = e_\alpha^+ \cdot \cos \theta(t) + e_\beta^+ \cdot \sin \theta(t) \quad [35]$$

$$e_q^+ = -e_\alpha^+ \cdot \sin \theta(t) + e_\beta^+ \cdot \cos \theta(t) \quad [36]$$

PLL Backward: bloque de sincronización principal en el dominio discreto. Cuenta con diferentes subsistemas que permiten obtener la fase de la señal de red  $\theta(t)$ , destacando un integrador discreto (PI) y a continuación un VCO (Voltage-controlled oscillator) (62).

### 2.2.8 Modelo Predictivo del Desequilibrio del Bus-DC

El Bus-DC, situado entre el rectificador y el inversor en un convertidor multinivel, tiene como función estabilizar la tensión continua  $V_{DC}$  que se obtiene de uno, y aportar los diferentes niveles de tensión que necesita el otro. Para el caso concreto de un convertidor 3L-NPC, el Bus-DC está compuesto por dos condensadores idealmente iguales, por lo que teóricamente también, sobre cada uno existirá una tensión de  $V_{DC}/2$ . Además, el punto central de unión de los condensadores, denominado “punto neutro”, se fija como la referencia de tensión ‘0’ para el inversor, por lo que de esta configuración se obtienen los 3 niveles de tensiones posibles para el convertidor:  $+V_{DC}/2$ ,  $-V_{DC}/2$  y 0 tal como se muestra en la Figura 16.

El Bus-DC se diseña para que ambos condensadores sean prácticamente idénticos, y con ello conseguir dos tensiones iguales. Sin embargo, al existir una conexión entre el inversor y el punto central de referencia ‘0’, en ciertas ocasiones o momentos puntuales, se crea una corriente  $i_0$  que produce un desequilibrio de las dos tensiones. Esto afecta negativamente al funcionamiento del inversor en ciertos estados de conmutación, ya que, aunque se presupone que cada rama contará con un nivel de tensión ( $+V_{DC}/2$ , 0 o  $-V_{DC}/2$ ), en realidad aparece una desviación en la tensión  $\Delta V$ . En los estados de conmutación que no generen corriente  $i_0$ , no se producirá el desequilibrio comentado.

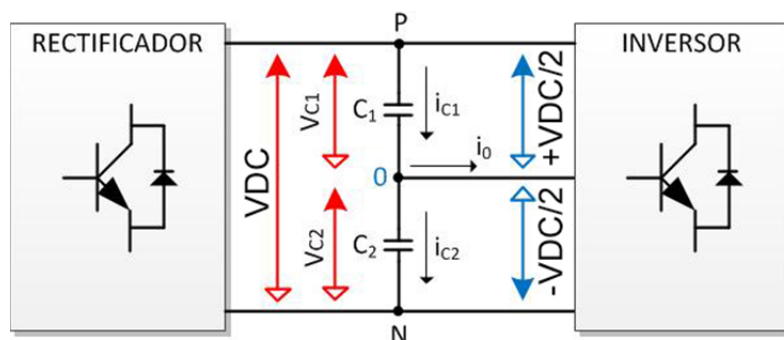


Figura 16. Esquema eléctrico del Bus-DC, puntos y valores de tensión para un convertidor 3L-NPC.

Para contrarrestar el desequilibrio del Bus-DC, en el Algoritmo de Control Predictivo se incluye en la función de coste la predicción del valor de desequilibrio del bus, entendiéndose este como el valor absoluto de la diferencia entre las tensiones de los dos condensadores, para el instante  $k+1$  y para cada estado de conmutación  $j$  de los posibles:

$$\text{Desequilibrio BusDC} = |\Delta V_c(j, k+1)| = |V_{C1} - V_{C2}| \quad [37]$$

Como ya se ha comentado anteriormente, el desequilibrio del Bus-DC es causado por la corriente  $i_0$ . Según el circuito de la Figura 16, si se consideran ambos condensadores iguales ( $C_1 = C_2 = C$ ) esta corriente queda definida mediante la relación:

$$i_0 = i_{c1} - i_{c2} = C1 \frac{dV_{C1}}{dt} - C2 \frac{dV_{C2}}{dt} \approx C \frac{d(V_{C1} - V_{C2})}{dt} = C \frac{d\Delta V_c}{dt} \quad [38]$$

Al igual que se hizo con la predicción de las corrientes de red, si en la expresión [38] se aproxima la derivada temporal como el incremento entre el instante  $k$  y el anterior  $k-1$ , la corriente se obtendría como:

$$i_0 \approx C \frac{\Delta V_c(k) - \Delta V_c(k-1)}{T_s} \quad [39]$$

Despejando  $\Delta V_c(k)$  de [39] y sustituyendo el instante  $k$  por  $k+1$ , finalmente se obtiene la expresión que permite predecir el desequilibrio del Bus-DC en función de la corriente  $i_0$ :

$$\Delta V_c(k+1) = \frac{T_s}{C} i_0(k+1) + \Delta V_c(k) \quad [40]$$

Como se observa, se necesita conocer el desequilibrio actual  $\Delta V_c(k)$  para que el controlador pueda minimizar este efecto, y por tanto se deben muestrear las tensiones en ambos condensadores del Bus-DC. Además, se debe conocer la predicción de corriente  $i_0(k+1)$ , que dependerá como veremos a continuación, únicamente del estado de conmutación en el que se configure el inversor.

Profundizando más sobre el tema (4) (42), se pueden definir cuatro grupos de estados de conmutación según los efectos que producen en  $i_o$  en un inversor 3L-NPC: vectores nulos, pequeños, medianos y largos. Esta clasificación está directamente relacionada con la distancia del estado de conmutación al centro de la constelación en un inversor 3L-NPC. No obstante, en cuanto a cómo afectan al desequilibrio del Bus-DC, se pueden distinguir tres tipos de estados de conmutación:

- **Vectores Nulos:** formados por aquellos estados que no crean ningún camino posible de corriente  $i_o$ , y por tanto no provocan un desequilibrio. Estos vectores son los asociados a los estados  $j=0$ ,  $j=1$  y  $j=2$  que conectan todas las ramas al mismo nivel de tensión (todas a 0, todas a P o todas a N), o bien por estados en los que ninguna de las ramas se conectan al punto neutro 0.
- **Vectores Positivos:** formados por los estados que generan una corriente  $i_o$  igual a alguna de las corrientes de alguna rama ( $i_a$ ,  $i_b$  o  $i_c$ ). Esta condición se produce cuando solo una rama está conectada al 0, y las otras dos a P o N.
- **Vectores Negativos:** formados por estados que generan un corriente  $i_o$  igual a alguna de las corrientes de alguna rama, pero de signo contrario ( $-i_a$ ,  $-i_b$  o  $-i_c$ ). Esta condición se produce cuando dos de las tres ramas están conectadas a 0, siendo  $i_o$  negativa e igual a la corriente de la rama que no lo está.

En la Figura 17 se pueden ver ejemplos de tres estados de conmutación para cada uno de los anteriores casos.

Estudiando a qué tipo concreto pertenece cada estado de conmutación  $j$ , se puede obtener la corriente  $i_o(j,k+1)$  que va a generar mientras esté activo, y por tanto se puede predecir el desequilibrio  $\Delta V_c(j,k+1)$  que generará usando la expresión [ 40]. La Tabla 5 muestra el valor de corriente  $i_o$  generada por cada uno de los estados del inversor, así como el grupo al que pertenece.




Figura 17. Ejemplos de desequilibrios del Bus-DC formado por los diferentes tipos de vectores o estados de conmutación: (a) Vector nulo  $j=1$  (N,N,N), (b) Vector positivo  $j=16$  (P,0,N), (c) Vector negativo  $j=11$  (0,0,P).

Tabla 5. Diferentes corrientes  $i_0$  generadas por los estados de conmutación en un inversor 3L-NPC.

Nº Estado (j)	Categoría	Vector de conmutación	$i_0$
0	Nulo	(0,0,0)	0
1	Nulo	(N,N,N)	0
2	Nulo	(P,P,P)	0
3	Negativo	(P,0,0)	$-i_a$
4	Positivo	(0,N,N)	$i_a$
5	Positivo	(P,P,0)	$i_c$
6	Negativo	(0,0,N)	$-i_c$
7	Negativo	(0,P,0)	$-i_b$
8	Positivo	(N,0,N)	$i_b$
9	Positivo	(0,P,P)	$i_a$
10	Negativo	(N,0,0)	$-i_a$
11	Negativo	(0,0,P)	$-i_c$
12	Positivo	(N,N,0)	$i_c$
13	Positivo	(P,0,P)	$i_b$
14	Negativo	(0,N,0)	$-i_b$
15	Nulo	(P,N,N)	0
16	Positivo	(P,0,N)	$i_b$
17	Nulo	(P,P,N)	0
18	Positivo	(0,P,N)	$i_a$
19	Nulo	(N,P,N)	0
20	Positivo	(N,P,0)	$i_c$
21	Nulo	(N,P,P)	0
22	Positivo	(N,0,P)	$i_b$
23	Nulo	(N,N,P)	0
24	Positivo	(0,N,P)	$i_a$
25	Nulo	(P,N,P)	0
26	Positivo	(P,N,0)	$i_c$

Por último, debemos hacer notar que la corriente  $i_0$  se obtiene a partir de alguna de las corrientes trifásicas  $i_a$ ,  $i_b$  o  $i_c$ , sin embargo, como ya se ha comentado, la predicción de las corrientes se realiza en componentes  $\alpha\beta$ . Por ello y en última instancia, para llegar a predecir el desequilibrio  $\Delta V_c(k+1)$ , se debe realizar primero una transformación de corrientes  $i_\alpha(k+1)$  y  $i_\beta(k+1)$  a trifásicas  $i_a(k+1)$ ,  $i_b(k+1)$  e  $i_c(k+1)$ , utilizando expresiones inversas a las vistas en [ 2] y [ 3]:

$$i_a = \sqrt{\frac{2}{3}} i_\alpha \quad [41]$$

$$i_b = -\sqrt{\frac{1}{6}} i_\alpha + \frac{\sqrt{2}}{2} i_\beta \quad [42]$$

$$i_c = -\sqrt{\frac{1}{6}} i_\alpha - \frac{\sqrt{2}}{2} i_\beta \quad [43]$$

### 2.2.9 Modelo Predictivo de la Frecuencia de Conmutación de los IGBT

Como ya se ha comentado, la frecuencia de conmutación de los IGBT influye en gran medida en la eficiencia de la conversión del inversor, por tanto, su minimización constituye un objetivo de control para el Algoritmo de Control Predictivo. A mayor frecuencia de conmutación, más pérdidas de potencia se tendrán, mayor estrés para los transistores, y a la vez mayor ruido de alta frecuencia y armónicos se introducirán en la red.

Predecir la frecuencia a la que conmutarán los IGBT del inversor, es equivalente a predecir el número de cambios o de conmutaciones que se producirán en las tres ramas del inversor durante la transición del estado actual  $i$ , al futuro estado  $j$ . Este número de conmutaciones que se producen, entre el tiempo transcurrido entre muestra y muestra, que será el tiempo máximo en pasar del estado  $i$  al  $j$ , debe ser minimizado para asegurar que la frecuencia de conmutación también se minimice. Al tener en cuenta la reducción del número de conmutaciones en una transición entre estados, que definimos como  $Nc(i,j)$ , estamos aportando al controlador la herramienta que le permitirá elegir un estado que reduzca la frecuencia de conmutación global, entre varios que a priori puedan ofrecer un error de *tracking* o desequilibrio de Bus-DC parecido.

Haciendo uso de lo visto en el apartado 2.2.2, en el que se muestran los diferentes cambios que se producen durante las transiciones y las secuencias correctas, se pueden obtener el número de conmutaciones que se producen al cambiar entre los diferentes niveles, en cada una de las ramas.

Tabla 6. Número de conmutaciones en transiciones de estados de cada rama del inversor 3L-NPC.

	0	P	N
0	0	2	2
P	2	0	4
N	2	4	0

Con esta información, se genera una matriz bidimensional simétrica como la mostrada en la Figura 18 con la que se puede conocer el número de cambios totales (incluyendo las tres ramas) entre estados  $Nc(i,j)$ .

	Estado futuro j																										
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26
Estado actual i	0	6	6	2	4	4	2	2	4	4	2	2	4	4	2	6	4	6	4	6	4	6	4	6	4	6	4
	1	6	0	12	8	2	10	4	8	2	10	4	8	2	10	4	4	6	8	6	4	6	8	6	4	6	8
	2	6	12	0	4	10	2	8	4	10	2	8	4	10	2	8	8	6	4	6	8	6	4	6	8	6	4
	3	2	8	4	0	6	2	4	4	6	6	4	4	6	2	4	4	2	4	6	8	6	8	6	8	6	4
	4	4	2	10	6	0	8	2	6	4	8	6	6	4	8	2	2	6	6	4	6	8	10	8	6	4	6
	5	4	10	2	2	8	0	6	7	8	4	6	6	8	4	6	6	4	2	4	6	4	6	8	10	8	6
	6	2	4	8	4	2	6	0	4	2	6	4	4	6	6	4	4	2	4	2	4	6	8	6	8	6	8
	7	2	8	4	4	6	7	4	0	6	2	4	4	6	6	4	8	6	4	2	4	2	4	6	8	6	8
	8	4	2	10	6	4	8	2	6	0	8	2	6	4	8	6	6	4	6	4	2	4	6	4	6	8	8
	9	4	10	2	6	8	4	6	2	8	0	6	2	8	4	6	10	8	6	4	6	4	2	4	6	4	6
	10	2	4	8	4	6	6	4	4	2	6	0	4	2	6	4	8	6	8	6	4	2	4	2	4	6	8
	11	2	8	4	4	6	6	4	4	6	2	4	0	6	2	4	8	6	8	6	8	6	4	2	4	2	4
	12	4	2	10	6	4	8	6	6	4	8	2	6	0	8	2	6	8	10	8	6	4	6	4	2	4	6
	13	4	10	2	2	8	4	6	6	8	4	6	2	8	0	6	6	4	6	8	10	8	6	4	6	4	2
	14	2	4	8	4	2	6	4	4	6	6	4	4	2	6	0	4	6	8	6	8	6	8	6	4	2	4
	15	6	4	8	4	2	6	4	8	6	10	8	8	6	6	4	0	2	4	6	8	10	12	10	8	6	4
	16	4	6	6	2	6	4	2	6	4	8	6	6	8	4	6	2	0	2	4	6	8	10	8	10	8	6
	17	6	8	4	4	6	2	4	4	6	6	8	8	10	6	8	4	2	0	2	4	6	8	10	12	10	8
	18	4	6	6	6	4	4	2	2	4	4	6	6	8	8	6	6	4	2	0	2	4	6	8	10	8	10
	19	6	4	8	8	6	6	4	4	2	6	4	8	6	10	8	8	6	4	2	0	2	4	6	8	10	12
	20	4	6	6	6	8	4	6	2	4	4	2	6	4	8	6	10	8	6	4	2	0	2	4	6	8	10
	21	6	8	4	8	10	6	8	4	6	2	4	4	6	6	8	12	10	8	6	4	2	0	2	4	6	8
	22	4	6	6	6	8	8	6	6	4	4	2	2	4	4	6	10	8	10	8	6	4	2	0	2	4	6
	23	6	4	8	8	6	10	8	8	6	6	4	4	2	6	4	8	10	12	10	8	6	4	2	0	2	4
	24	4	6	6	6	4	8	6	6	8	4	6	2	4	4	2	6	8	10	8	10	8	6	4	2	0	2
	25	6	8	4	4	6	6	8	8	8	6	8	4	6	2	4	4	6	8	10	12	10	8	6	4	2	0
	26	4	6	6	2	4	4	6	6	8	8	6	6	4	4	2	2	4	6	8	10	8	10	8	6	4	2

Figura 18. Matriz de transiciones entre pares de estados con el número de conmutaciones que se producen en un inversor 3L-NPC.



## 2.3 Modelo Completo del Algoritmo de Control Predictivo

Una vez se han explicado y definido cada uno de los bloques que componen el controlador basado en el Algoritmo de Control Predictivo, a continuación, se resumirá su funcionamiento y las señales implicadas en el mismo.

La Figura 19 muestra el esquema funcional por bloques del controlador MPC. En lo que sigue se ha optado por describir cada uno de ellos según van apareciendo en el flujo de datos del algoritmo.

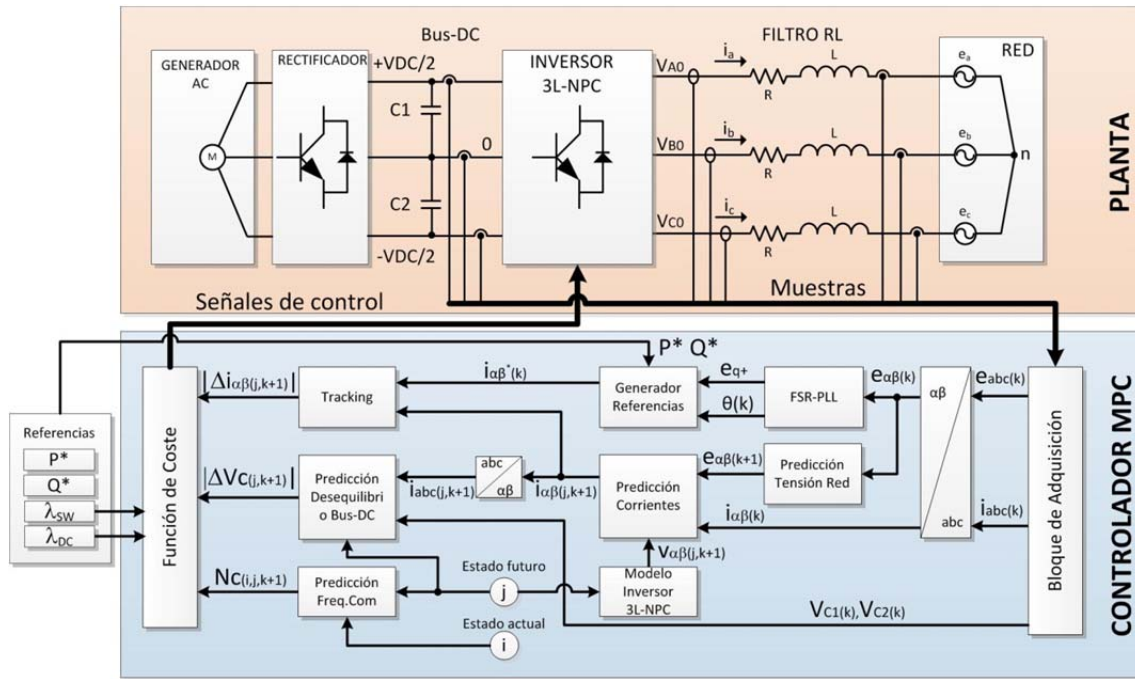


Figura 19. Diagrama de bloques general del Algoritmo de Control Predictivo sobre un inversor de 3 niveles auto-sincronizado con la fase de la red.

Para evaluar los modelos predictivos que se usan en el algoritmo, se necesita muestrear algunas variables ya comentadas en puntos anteriores. El muestreo de dichas señales se lleva a cabo mediante convertidores AD e interfaces especiales de control de los mismos. A continuación, se listan a modo de resumen todas las señales necesarias, denotando con  $(k)$  el hecho de que se trata de señales discretas con período de muestreo  $T_s$ :

- Tensiones del Bus-DC:  $V_{C1}(k)$  y  $V_{C2}(k)$  que serán las tensiones de los condensadores del Bus-DC, utilizadas para cuantificar el desequilibrio del bus.

- Corrientes generadas en cada rama:  $i_a(k)$ ,  $i_b(k)$  e  $i_c(k)$ , o  $i_{abc}(k)$ , correspondientes a las corrientes trifásicas de la red eléctrica. Las muestras de estas corrientes son necesarias para aplicar los modelos predictivos, además de ser entradas a la función de optimización del algoritmo predictivo.
- Tensiones de la red eléctrica:  $e_a(k)$ ,  $e_b(k)$  y  $e_c(k)$ , o  $e_{abc}(k)$ , correspondientes a las tensiones trifásicas de la red eléctrica. Necesarias en los modelos predictivos y en la generación de referencias sincronizadas mediante el FSR-PLL.

A continuación, las corrientes de cada rama y las tensiones de red, son convertidas a componentes  $\alpha\beta$  usando las expresiones genéricas [ 2] y [ 3]. Esta conversión se realiza para reducir la carga computacional del algoritmo. En la Figura 20 se muestran, como ejemplo, las señales de las tensiones  $abc$  de red convertidas en componentes  $\alpha\beta$ , desfasadas  $\pi/2$  (o  $90^\circ$ ). Además, existe un aumento de amplitud de  $\sqrt{3/2} \approx 1.225$ .

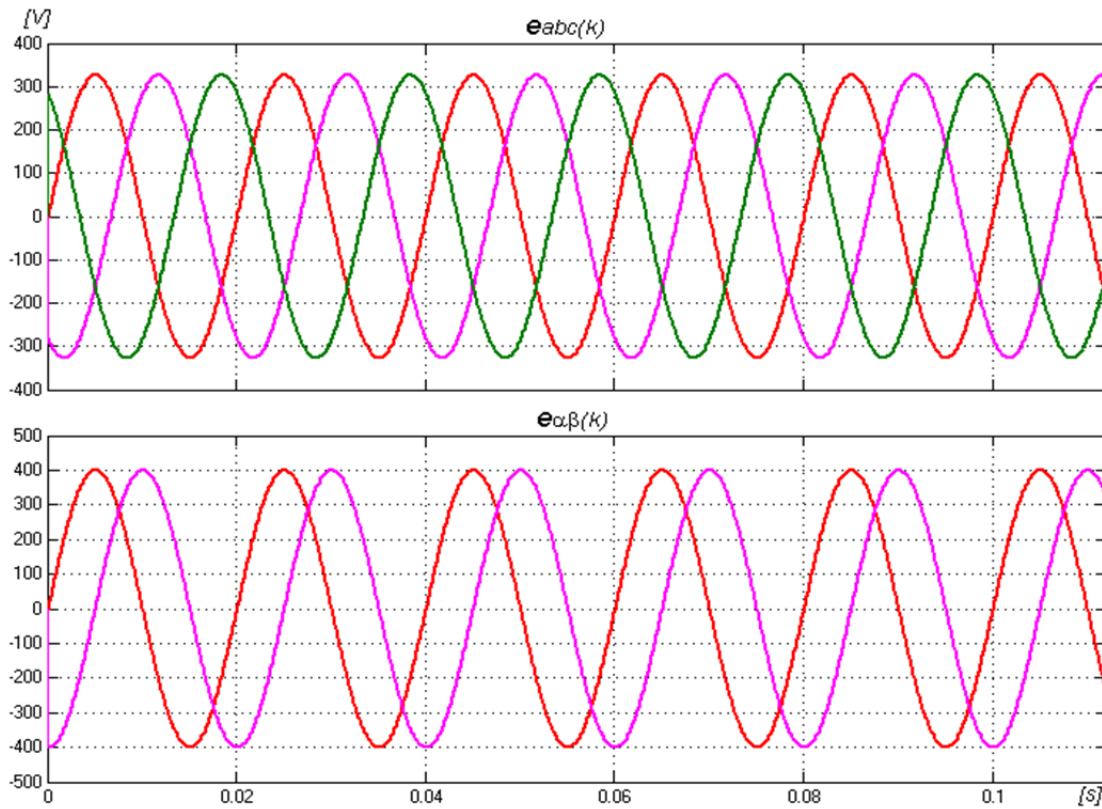


Figura 20. Ejemplo de conversión de tensiones trifásicas  $e_{abc}$  a  $e_{\alpha\beta}$ .

Las tensiones de red  $e_{\alpha\beta}(k)$  son necesarias para la predicción de las propias tensiones de red  $e_{\alpha\beta}(k+1)$  descritas por [ 16][ 17], las cuales se usan en el modelo de predicción de corriente.

Por otro lado, las tensiones  $e_{\alpha\beta}(k)$  se usan para obtener la fase fundamental de red  $\theta(k)$  y las componentes  $e_{q+}$  y  $e_{d+}$  (aunque esta última tenderá a 0) de la secuencia positiva mediante la utilización del bloque FSR-PLL. Posteriormente, aplicando [ 13],[ 14],[ 29] y [ 30] en el bloque de generación de las corrientes de referencia, se obtienen  $i_{\alpha\beta}^*(k)$ . La Figura 21 muestra la evolución de las señales  $e_{dq+}$ , la fase  $\theta(k)$  y la relación en cuando a las fases de las tensiones  $e_{\alpha\beta}(k)$  respecto a las referencias  $i_{\alpha\beta}^*(k)$  generadas, para el caso en que  $P^*=100\text{kW}$  y  $Q^*=0\text{kVAr}$ , o dicho de otro modo, toda la potencia es activa y por tanto las corrientes deben estar en fase con las tensiones.

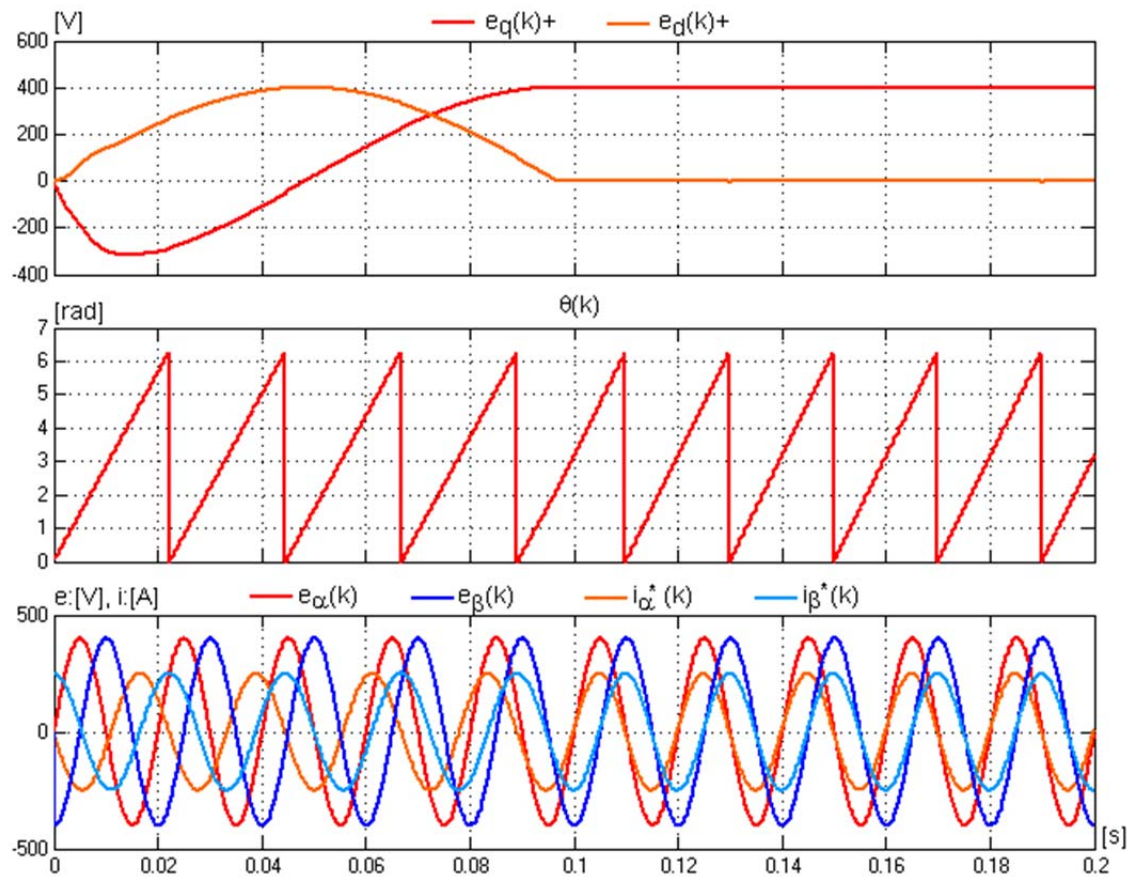


Figura 21. Señales principales implicadas en el bloque FSR-PLL y la generación de consignas en  $\alpha\beta$ .

En la Figura 22 se muestra un ejemplo en el que se han introducido como referencias  $P^*=80\text{kW}$  junto a una  $Q^*=+60\text{kVAr}$ , y una  $Q^*=-60\text{kVAr}$ . Como se ve, cuando  $Q>0$  existirá un comportamiento inductivo, al estar la corriente retrasada respecto a la tensión. Por el contrario, cuando  $Q<0$  hay un comportamiento capacitivo y la corriente está adelantada respecto a la tensión.

Una vez generadas las corrientes de referencia  $i_{\alpha\beta}^*(k)$  en función de las consignas de potencia, muestreadas las corrientes  $i_{abc}(k)$  y convertidas en  $i_{\alpha\beta}(k)$ , y predichos los valores de las tensiones de red  $e_{\alpha\beta}(k+1)$ , se puede obtener la predicción de corrientes  $i_{\alpha\beta}(j,k+1)$  para cada estado de conmutación  $j$  usando [ 12][ 13]. En este proceso influyen los valores  $v_{\alpha}(k+1)$  y  $v_{\beta}(k+1)$  que son propios para cada estado  $j$  según el modelo del inversor visto en la Tabla 4.




Figura 22. Ejemplo de relación entre la tensión  $e_{\alpha}(k)$  y la corriente de referencia  $i_{\alpha}^*(k)$  cuando hay una consigna  $Q^*$  positiva y negativa.

En la Figura 23 se muestra un ejemplo de corrientes  $i_{\alpha}(k+1)$  predichas para cada uno de los 27 estados diferentes de conmutación del inversor 3L-NPC durante un intervalo de tiempo de la ejecución del algoritmo implementado, funcionando con  $T_s=100\mu\text{s}$ . Como se puede observar, con cada muestra que llega al modelo, se deben predecir las corrientes para cada estado tanto en  $\alpha$  como en  $\beta$ . Posteriormente, el estado que minimice la función de coste, será seleccionado como óptimo. El objetivo más importante del control que se lleva a cabo el MPC, es la minimización del error o desviación que se produce entre el vector de corriente real y la referencia, llamado aquí como error de tracking:  $|i_{\alpha\beta}^*(k) - i_{\alpha\beta}(k)|$ . Este error se calcula sumando las desviaciones de ambas componentes.



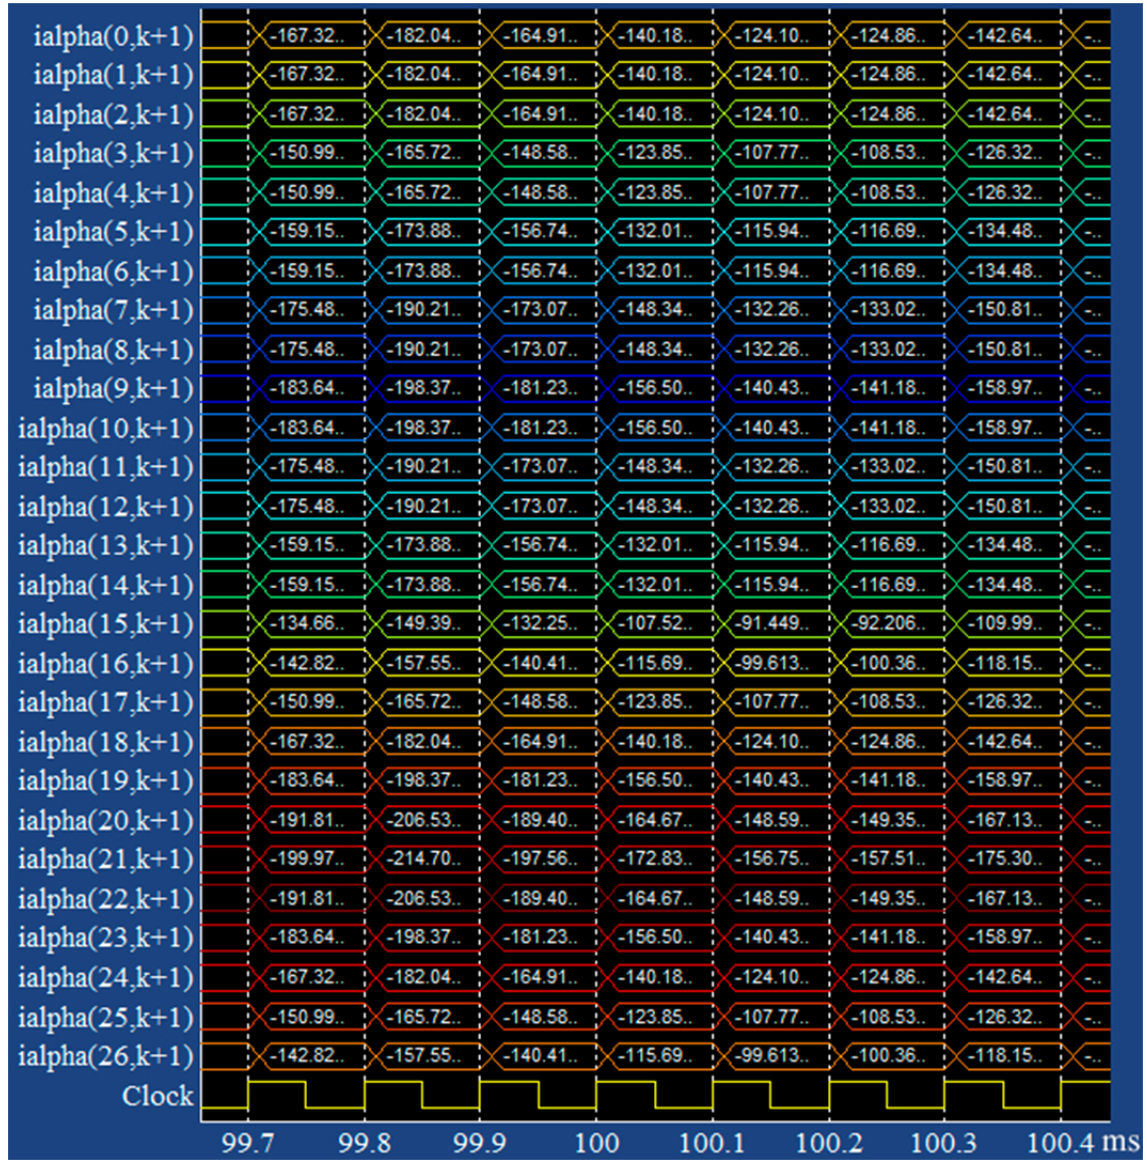


Figura 23. Ejemplo de corrientes  $i_{\alpha}(k+1)$  predichas tras aplicar el modelo predictivo para cada estado de conmutación  $0 \leq j \leq 26$  en un inversor 3L-NPC para varios períodos de ejecución.

Con la predicción de la corriente que generaría cada estado de conmutación, se puede a su vez predecir la corriente  $i_0$  y por tanto, el desequilibrio del Bus-DC,  $\Delta V_c(j,k+1)$ , usando las correspondencias de la Tabla 5 sobre la expresión [40]. Del mismo modo, conocido el estado actual del convertidor,  $i$ , se puede obtener el número de conmutaciones  $N_c(i,j)$  necesarias para alcanzar el nuevo estado  $j$ . Con estos dos términos conocidos, junto con el error de tracking, el algoritmo del MPC calcula la función de coste descrita en [20] para cada uno de los resultados obtenidos de cada estado, ponderando los dos anteriores términos con sus factores de peso  $\lambda_{DC}$  y  $\lambda_{SW}$ . Así se obtendrá, en cada instante de muestreo y al final del proceso, un conjunto de 27

valores de la función de coste, uno por cada estado. El algoritmo de control, simplemente selecciona aquel estado que minimiza la función de coste y, seguidamente, genera las correspondientes señales de control para configurar al convertidor en dicho estado óptimo, completando así el ciclo de control hasta el siguiente instante de muestreo. La Figura 24 muestra primeramente la evolución de la selección del estado de conmutación óptimo  $j_{opt}$ , que selecciona el controlador en cada instante de muestreo. Como se puede ver, durante la generación de las corrientes, el controlador selecciona casi todos los estados siguiendo una distribución periódica, alternando entre estados grandes, que son los que generan tensiones  $V_{a\beta}$  más elevadas, y estados pequeños que las generan menores.

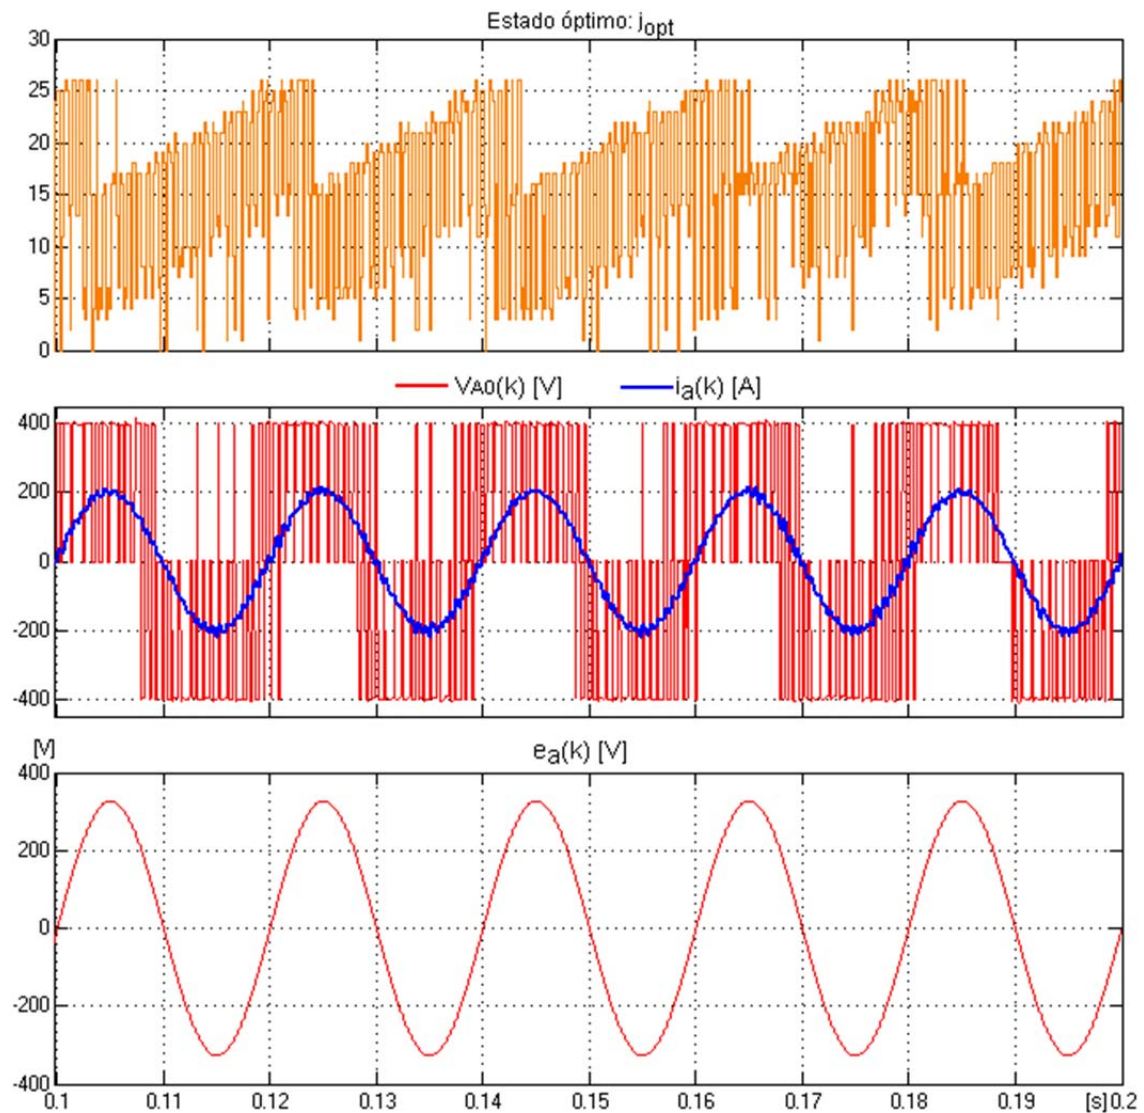


Figura 24. Variación del estado de conmutación óptimo al generar las corrientes. Relación entre tensión de salida del inversor  $V_{A0}$  y la corriente  $i_a(t)$  generada junto a la tensión de red  $e_a(t)$ .

Este efecto se puede ver más claramente en la Figura 24, donde se observa la relación entre la tensión de salida de una rama del inversor 3L-NPC, en este caso la fase  $a$  y por tanto  $V_{A0}$ , y la corriente que se genera  $i_a(k)$ . Como se puede ver en la figura, en la generación del máximo de la corriente, intervienen estados que fijan una tensión de  $+V_{DC}/2$  a la salida del inversor, y en el caso de los mínimos  $-V_{DC}/2$ . Por otro lado, los cruces por cero de la señal, se crean cuando se fijan alternativamente estados con  $+V_{DC}/2$ , con otros de  $-V_{DC}/2$ .

## 2.4 Estudio de la sensibilidad del controlador ante variaciones de distintos parámetros

Como se ha visto hasta ahora, el Algoritmo de Control Predictivo se basa en diversos modelos, en los que se han considerado los parámetros conocidos y constantes. Sin embargo, la realidad es que existen incertidumbres de modelado que afectan a estos parámetros como tolerancia de componentes, dependencia con la temperatura, etc. En este apartado, se va a evaluar la sensibilidad que presenta el controlador propuesto ante cambios en los parámetros del modelado.

Para cuantificar el efecto de las variaciones de los parámetros en el funcionamiento del controlador, se definen diversos índices de calidad que se calcularán sobre las corrientes de salida de convertidor. Como se verá detalladamente en el CAPÍTULO 3, en este estudio se han considerado los siguientes índices de calidad:

- Error medio de tracking, medido como la desviación media de las corrientes generadas respecto a las de referencia.
- Distorsión armónica total o THD.
- Desequilibrio del Bus-DC medido como la diferencia de tensiones de los condensadores en valor absoluto:  $|\Delta V_c|$ .
- Frecuencia de conmutación de los IGBT.

De igual manera, a los efectos del estudio de sensibilidad, se considerará una función de coste fija, esto es, sin cambios en los factores de peso  $\lambda_{DC}$  y  $\lambda_{SW}$ .

### 2.4.1 Resistencia e inductancia del filtro de acoplo de red: $R$ y $L$

El filtro de acoplo con la red eléctrica tiene dos funciones principales: por un lado permite la conexión del inversor con la red eléctrica, y por otro lado, actúa filtrando las señales de corriente de red. Existen diferentes alternativas para el diseño del filtro, en función de su estructura y elementos constitutivos, sin embargo, en esta tesis se ha hecho uso de un filtro RL como se vio en el punto 2.2.4.

Como su nombre indica, el filtro RL está compuesto por una resistencia  $R$  en serie con una inductancia  $L$ . Por tanto  $R$  y  $L$  son los parámetros cuyas incertidumbres de modelado pueden afectar el funcionamiento del Algoritmo de Control Predictivo. No obstante, son parámetros cuya variación es de difícil cuantificación y sus efectos son complicados de mitigar. La identificación “online” de los valores de la resistencia y la inductancia podría ser una alternativa para posteriormente ajustar en tiempo real el algoritmo de control, sin embargo, este proceso puede resultar muy complejo y aumentaría la dificultad de implementación del controlador.

Tanto  $R$  como  $L$  son elementos eléctricos que poseen tolerancias (en algunas ocasiones altas) y además pueden verse afectados por variables externas como la temperatura. Por ello, podemos concluir en términos generales, que los valores de  $R$  y  $L$  serán en la realidad  $R+\Delta R$ , y  $L+\Delta L$ .

Además de lo anterior, aunque idealmente el filtro de acoplo es el único elemento eléctrico entre el convertidor y la red, en la realidad existen efectos resistivos e inductivos en los conductores que unen los elementos, que llamaremos  $R_{LINE}$  y  $L_{LINE}$ , lo que se traduce en que para un caso real, el valor total de los elementos serán:

$$R_{TOTAL} = R + \Delta R + R_{LINE} = R + \Delta R_T \quad [44]$$

$$L_{TOTAL} = L + \Delta L + L_{LINE} = L + \Delta L_T \quad [45]$$

La Figura 25 muestra el circuito eléctrico real que se tiene como carga del sistema para el convertidor, incluyendo el error de los propios elementos del filtro y los parámetros de los conductores. Como se ve, se considera que las tres fases eléctricas se comportan de la misma manera.






Figura 25. Circuito eléctrico real de la carga del convertidor 3L-NPC.

Teniendo en cuenta, como suele ser normal, que tanto  $R_{LINE}$  y  $L_{LINE}$ , como  $\Delta R$  y  $\Delta L$  sean de magnitud bastante inferior a  $R$  y  $L$ , para estudiar el efecto de la variación sobre el controlador de esta resistencia e inductancia, se considerará que tienen un valor nominal  $R$  y  $L$ , y una variación  $\Delta R_T$  y  $\Delta L_T$ , donde se incluirían todos los efectos de variación de sus valores. Para el caso que nos ocupa, se considerará un valor nominal de  $R=3.63\text{m}\Omega$  y de  $L=2\text{mH}$ , y una variación máxima de  $\pm 20\%$  en ambos valores ( $\Delta R_T$  y  $\Delta L_T$ ), y se mostrarán los efectos que se producen sobre el funcionamiento del controlador, en particular sobre la corriente de salida. Un resumen de todos los parámetros de configuración del sistema para realizar este estudio, se muestran a continuación:

Período de muestreo	$T_s = 100\mu\text{s}$ (10kHz)
Tensión Bus-DC	$V_{DC} = 800\text{ V}$
Tensión de red eléctrica	$e = 230\text{ V rms}$
Período de muestreo	$T_s = 100\mu\text{s}$
Resistencia nominal del filtro	<b><math>R = 3.63\text{ m}\Omega</math></b>
Inductancia nominal del filtro	<b><math>L = 2\text{ mH}</math></b>
Desviaciones de parámetros del filtro	<b><math>\pm 20\%</math></b>
Max. Potencia del convertidor	100 kVA
Referencia de potencia activa	$P^* = 100\text{ kW}$
Referencia de potencia reactiva	$Q^* = 0\text{ kVAr}$
Factor de peso del desequilibrio Bus-DC	$\lambda_{DC} = 1.2$
Factor de peso de la freq. de conmutación	$\lambda_{SW} = 1$

Comúnmente se suelen realizar estudios de Montecarlo para ver la relación entre ciertos parámetros de entrada, con la respuesta de un sistema. Sin embargo, de cara

a simplificar el estudio de la dependencia y que solo se pretende observar el tipo de relación, se optó por estudiar el efecto de un parámetro concreto sobre el sistema, considerando el resto de variables fijas, teniendo en cuenta solo la propia variación del parámetro observando la salida para cierto conjunto de valores del mismo(a modo de derivada parcial). De esta forma, el efecto producido por la variación del valor de la resistencia R, considerando L fija se muestra en la Tabla 7, mientras que el efecto producido por la variación de L con R fija, se muestra en la Tabla 8.

Tabla 7. Efecto de la variación de R = 3.63mΩ hasta un ±20%, con L = 2mH constante, sobre el funcionamiento del controlador.

R (mΩ)	L(mH)	$\Delta i_{\alpha\beta}(A)$	THD(%)	$\Delta V_c(V)$	$f_{sw}(Hz)$
2.90	2.00	10.91	10.66	5.49	1820
2.98	2.00	10.88	10.65	5.67	1843
3.05	2.00	10.91	10.77	5.33	1880
3.12	2.00	11.04	10.83	5.42	1882
3.19	2.00	11.10	10.85	5.36	1896
3.27	2.00	10.99	10.79	5.39	1887
3.34	2.00	10.80	10.64	5.75	1816
3.41	2.00	10.93	10.80	5.59	1916
3.48	2.00	10.90	10.67	5.50	1876
3.56	2.00	10.67	10.58	5.23	1854
3.63	2.00	10.62	10.58	5.56	1833
3.70	2.00	10.70	10.69	5.47	1847
3.78	2.00	10.70	10.58	5.48	1862
3.85	2.00	10.68	10.58	5.23	1866
3.92	2.00	10.74	10.57	5.72	1856
3.99	2.00	10.84	10.68	5.52	1854
4.07	2.00	10.76	10.68	5.30	1831
4.14	2.00	10.84	10.63	5.34	1854
4.21	2.00	11.40	11.01	5.21	1898
4.28	2.00	11.14	10.72	5.31	1833
4.36	2.00	11.02	10.75	5.39	1887

Tabla 8. Efecto de la variación de L = 2mH hasta un ±20%, con R = 3.63mΩ constante, sobre el funcionamiento del controlador.

R (mΩ)	L(mH)	$\Delta i_{\alpha\beta}(A)$	THD(%)	$\Delta V_c(V)$	$f_{sw}(Hz)$
3.63	1.60	16.90	14.57	5.26	2111
3.63	1.64	16.26	14.13	4.87	2140
3.63	1.68	15.21	13.54	5.16	2086
3.63	1.72	14.51	13.02	5.21	2076
3.63	1.76	13.97	12.59	5.31	2051

R (mΩ)	L(mH)	$\Delta i_{\alpha\beta}$ (A)	THD(%)	$\Delta V_c$ (V)	$f_{sw}$ (Hz)
3.63	1.80	13.51	12.27	5.19	2014
3.63	1.84	13.10	12.21	5.04	2029
3.63	1.88	12.47	11.74	5.07	1966
3.63	1.92	11.63	11.12	5.33	1909
3.63	1.96	11.39	10.96	5.17	1952
3.63	2.00	10.62	10.58	5.56	1833
3.63	2.04	10.79	10.63	5.33	1838
3.63	2.08	10.13	10.12	5.43	1793
3.63	2.12	9.99	10.09	5.41	1784
3.63	2.16	9.56	9.70	5.58	1727
3.63	2.20	9.17	9.45	5.94	1696
3.63	2.24	9.36	9.46	5.55	1727
3.63	2.28	9.03	9.29	5.95	1701
3.63	2.32	8.68	8.97	6.05	1657
3.63	2.36	8.79	9.01	5.75	1619
3.63	2.40	8.50	8.85	6.32	1551

A partir de los datos de las tablas anteriores, se muestran las siguientes figuras.




Figura 26. Efecto de una variación de R en torno a un 20% de su nominal sobre el tracking de corrientes y la distorsión armónica total (THD).




Figura 27. Efecto de una variación de  $R$  en torno a un 20% de su nominal sobre el desequilibrio del Bus-DC y la frecuencia de conmutación de los IGBT .




Figura 28. . Efecto de una variación de  $L$  en torno a un 20% de su nominal sobre el tracking de corrientes y la distorsión armónica total (THD).




Figura 29. Efecto de una variación de L en torno a un 20% de su nominal sobre el desequilibrio del Bus-DC y la frecuencia de conmutación de los IGBT.

Como se puede deducir de los resultados anteriores, la incertidumbre de modelado del filtro de acoplo con la red puede provocar que los índices de calidad del sistema sufran menor o mayor grado de deterioro. Además, se observa como el sistema es más sensible a variaciones de la inductancia L que a la resistencia R en cuanto a cómo afectan a los índices de calidad.

Como se puede apreciar, la desviación de corriente o error de tracking y el THD, dependen mínimamente del valor de la R. Por ejemplo, en lo que se refiere a  $\Delta i_{\alpha\beta}$ , la diferencia entre el máximo y mínimo error obtenido (11,1A y 10,57A respectivamente) es de tan solo 0,53A. Considerando que la amplitud de las corrientes de salida según las consignas, será de unos 250A en coordenadas  $\alpha\beta$ , esta diferencia representa un 0.2% del valor nominal. Del mismo modo, la diferencia de THD supone un 0,44%. No obstante se obtienen los valores de funcionamiento óptimos cuando R coincide con el valor nominal. Así mismo, en cuanto al desequilibrio del Bus-DC y a la frecuencia de conmutación de los IGBT, se puede ver cómo no existe relación alguna, manteniéndose ambos en torno al valor medio.

En cuanto al efecto sobre los índices de calidad de las variaciones de las L, se observa como el error de tracking y el THD siempre mejoran cuando se incrementa la L, y por el contrario siempre empeoran cuando se reduce. Ello se debe sobre todo a que, al aumentar la L, la frecuencia de corte del filtro es menor, reduciéndose el nivel de armónicos. De ello se deduce que siempre que L varíe hacia valores por encima del nominal, se obtendrán mejores resultados. Para el desequilibrio del Bus-DC y la

frecuencia de conmutación, se observa como siguen tendencias claramente contrarias: mientras que el desequilibrio del Bus-DC aumenta a medida que aumenta  $L$ , la frecuencia de conmutación se reduce. Ello se debe a que, al mejorar el filtrado, el controlador genera menos conmutaciones entre estados, lo que reduce la frecuencia de conmutación de los IGBT; por el contrario la corriente  $i_o$  que provoca el desequilibrio del Bus-DC se mantiene presente durante más tiempo, incrementando el desequilibrio de las tensiones.

En conclusión, el Algoritmo de Control Predictivo se ve afectado por las incertidumbres del modelado. En caso de variaciones extremas, se deberían medir o cuantificar los valores reales de la  $L$  y  $R$  totales, como podría ser el caso de “redes débiles” cuya impedancia puede variar considerablemente.

### **2.4.2 Período de muestreo: $T_s$**

La frecuencia de muestreo del sistema, es un parámetro sumamente importante en el funcionamiento del controlador. Desde el punto de vista del controlador,  $T_s$  está presente en los modelos matemáticos predictivos de casi todas las magnitudes que intervienen en el proceso: predicción de las corrientes de red [ 12][ 13], predicción del desequilibrio del Bus-DC [ 40] e incluso en el funcionamiento del SRF-PLL [ 32].

Aunque las señales de red que se muestrean son de 50Hz, existen otras como las tensiones de los condensadores del Bus-DC y la corriente  $i_o$  de desequilibrio, cuya frecuencia de variación dependerá directamente de  $T_s$ . Este período de muestreo debe ser lo suficientemente pequeño, para asegurar que el controlador no pierda información sobre la evolución de las señales que está controlando, y por tanto ante una desviación que se produzca, pueda empezar a corregir el defecto lo antes posible. El hecho de que se consiga mejor funcionamiento para una frecuencia de muestreo mayor, se contrapone con los requerimientos de implementación, ya que según se reduce el periodo de muestreo, lo hace también el tiempo disponible para que ejecutar las distintas tareas en las que se descompone el algoritmo de control.

La Figura 30 muestra un ejemplo en el que se muestra la corriente  $i_\alpha$  generada por un controlador MPC sobre un convertidor 3L-NPC, trabajando a una frecuencia de 10kHz, y de 100kHz. Así mismo, se recogen los datos del error de tracking, el THD de las corrientes y la corriente de referencia  $i_\alpha^*$ .




Figura 30. Ejemplo de corriente  $i_{\alpha}$  generada por el controlador MPC con un periodo de muestreo de  $T_s=100\mu s$  (10kHz) y  $T_s=10\mu s$  (100kHz).

Por tanto, la elección de la frecuencia de muestreo será el resultado de un compromiso entre prestaciones y la capacidad del hardware de implementación. A modo de ejemplo, en la Tabla 9 se muestra el efecto sobre los índices de calidad de la variación de la frecuencia de muestreo para un sistema con los siguientes datos:

Tensión Bus-DC	$V_{DC} = 800 \text{ V}$
Tensión de red eléctrica	$e = 230 \text{ V rms}$
Período de muestreo	<b><math>T_s = 10 \leftrightarrow 200 \mu s</math></b>
Resistencia nominal del filtro	$R = 0.063 \Omega$
Inductancia nominal del filtro	$L = 2 \text{ mH}$
Max. Potencia del convertidor	100 kVA
Referencia de potencia activa	$P^* = 100 \text{ kW}$
Referencia de potencia reactiva	$Q^* = 0 \text{ kVAr}$
Factor de peso del desequilibrio Bus-DC	$\lambda_{DC} = 1.2$
Factor de peso de la freq. de conmutación	$\lambda_{SW} = 1$

Tabla 9. Efecto de la variación de  $T_s$  sobre el funcionamiento del controlador MPC.

$T_s (\mu s)$	$f_s (\text{kHz})$	$\Delta i_{\alpha, \beta} (A)$	THD(%)	$\Delta V_c (V)$	$f_{sw} (Hz)$
200	5.00	20.89	12.78	11.22	10
190	5.26	21.39	13.33	9.38	102

Ts (μs)	fs(kHz)	$\Delta i\alpha\beta(A)$	THD(%)	$\Delta Vc(V)$	fsw(Hz)
180	5.56	18.58	11.65	10.27	182
170	5.88	18.22	11.53	8.71	348
160	6.25	16.56	10.69	9.15	440
150	6.67	16.27	10.54	7.85	643
140	7.14	14.75	9.39	7.16	782
130	7.69	13.83	8.74	6.49	973
120	8.33	12.98	8.35	6.61	1173
110	9.09	11.50	7.58	5.82	1463
100	10.00	10.81	7.02	5.45	1823
90	11.11	9.09	5.98	4.94	2102
80	12.50	8.53	5.82	4.51	2647
70	14.29	7.75	5.53	3.71	3427
60	16.67	6.21	4.69	3.56	4132
50	20.00	5.13	3.84	3.06	5140
40	25.00	4.38	3.59	2.43	6910
30	33.33	3.36	3.17	1.86	9446
20	50.00	2.23	2.01	1.42	13715
10	100.00	1.47	1.86	1.02	22473




Figura 31. Efecto sobre los índices de calidad debido a la variación del período de muestreo  $T_s$  del sistema.



Como se observa en la gráfica de la Figura 31, todos los índices de calidad empeoran frecuencias de muestreo  $f_s = 1/T_s$  bajas, y además lo hacen linealmente, y solo la frecuencia de conmutación disminuye claramente cuando se reduce  $f_s$ , ya que en ese caso aumenta  $T_s$ , y por tanto, al ser el período de actualización de las señales menor, se espacian en el tiempo las transiciones de los IGBT. Al contrario de los otros parámetros, el efecto sobre la frecuencia de conmutación es exponencial. Hay que aclarar también que estos datos se han obtenido manteniendo constantes todos los demás valores de configuración del controlador, pero cabría la posibilidad de que al trabajar con frecuencias de muestreo más bajas, que tienden a disminuir en exceso la frecuencia de conmutación de los IGBT y empeorar los otros índices de calidad, se pueda corregir el efecto modificando el factor de peso  $\lambda_{sw}$ . De igual manera, si la frecuencia de conmutación aumenta, aumentando  $\lambda_{sw}$  se consigue que el controlador sea más restrictivo. Este tipo de ajustes se estudiarán en el siguiente capítulo.

### 2.4.3 Tensión del bus-DC

Como ya se ha explicado, en el caso del inversor 3L-NPC, en sus salidas se dispone de una tensión que puede tomar los valores de  $+V_{DC}/2$ , 0 y  $-V_{DC}/2$ . En el otro extremo de cada fase están presentes las tensiones de red  $e_a$ ,  $e_b$  y  $e_c$  que tienen tensiones nominales de 230 V rms. Estas dos tensiones definen la corriente máxima que puede aportar el inversor, que en cuanto al valor de su módulo queda definida por la ecuación de su malla cuando la salida del inversor y la tensión de red están en fase:

$$I_{max} = \frac{\frac{V_{DC}}{2} - |e|}{|Z_L|} \quad [46]$$

Evidentemente, el valor  $V_{DC}$  influye en el valor de corriente máxima que se puede generar, y por tanto en la potencia suministrada por el convertidor. Debido a ello, se ha realizado un estudio para ver en qué medida afecta la variación de la tensión del Bus-DC  $V_{DC}$  al funcionamiento del convertidor, configurando el sistema con los siguientes datos:

Tensión Bus-DC	$V_{DC}=1000 \leftrightarrow 540 \text{ V}$
Tensión de red eléctrica	$e = 230 \text{ V rms}$
Período de muestreo	$T_s = 100 \mu\text{s}$
Resistencia nominal del filtro	$R = 0.063 \Omega$

Inductancia nominal del filtro	$L = 2 \text{ mH}$
Max. Potencia del convertidor	100 kVA
Referencia de potencia activa	$P^* = 100 \text{ kW}$
Referencia de potencia reactiva	$Q^* = 0 \text{ kVAr}$
Factor de peso del desequilibrio Bus-DC	$\lambda_{DC} = 1.2$
Factor de peso de la freq. de conmutación	$\lambda_{SW} = 1$

En la Tabla 10 se muestran los resultados de los índices de calidad obtenidos para una variación de la tensión  $V_{DC}$  desde los 1000V a los 600V.

Tabla 10. Efecto de la variación de  $V_{DC}$  sobre el funcionamiento del controlador MPC.

$V_{DC} \text{ (V)}$	$\Delta i_{\alpha\beta} \text{ (A)}$	THD(%)	$\Delta V_c \text{ (V)}$	$f_{sw} \text{ (Hz)}$
1000	13.36	8.84	5.3	2152
980	12.65	8.13	5.43	2040
960	13.08	8.34	5.11	2053
940	12.64	8.21	5.12	2108
920	12.68	7.89	5.014	2058
900	11.97	7.49	5.05	2045
880	11.33	7.6	5.23	2028
860	11.12	7.08	5.6	1895
840	11.03	6.91	5.52	1898
820	11.32	7.03	5.38	1890
800	10.79	6.50	5.54	1812
780	9.86	6.01	6.24	1698
760	10.35	6.26	5.34	1695
740	10.01	5.97	5.05	1592
720	9.74	5.67	5.52	1515
700	10.05	5.67	5.51	1428
680	9.57	5.35	5.42	1230
660	9.17	4.85	5.49	1163
640	10.74	5.49	5.88	1115
620	11.20	5.64	6.14	933
600	12.94	5.69	6.15	863
580	20.10	7.50	5.23	753
560	38.46	14.00	4.78	677
540	52.63	17.58	3.42	515

En la Figura 32 se muestran las variaciones de los índices de calidad elegidos, en función de la variación de la tensión del Bus-DC  $V_{DC}$ . El controlador ha sido ajustado con los factores de peso  $\lambda_{DC}$  y  $\lambda_{SW}$  para trabajar con  $V_{DC} = 800\text{V}$ . De los resultados

obtenidos, se puede ver que tanto el error de tracking, como el THD siguen la misma tendencia: permanecen casi constantes hasta que  $V_{DC}$  llega en torno a los 600V, si bien se observa que al aumentar la tensión desde los 800V, los errores van creciendo lentamente, debido a que cuando crece  $V_{DC}$  también crecen los desequilibrios del Bus-DC, y al tener una  $\lambda_{DC}$  fija, este efecto predomina sobre los otros dos (tracking y frecuencia de conmutación). A partir de los 600V, las tensiones  $V_{DC}/2$  a la salida del inversor están en torno a 300V, y a partir de ese momento, dichas tensiones son iguales o inferiores a la tensión de red, en torno a 320V de máximo. El efecto que se produce es que el inversor es incapaz de generar las corrientes necesarias, incrementándose exponencialmente los errores de seguimiento de las consignas. En la Figura 33 se muestra un ejemplo de las corrientes en componentes  $\alpha\beta$  respecto a las referencias, una vez se ha rebasado este umbral.




Figura 32. Efecto sobre los índices de calidad debido a la variación de la tensión  $V_{DC}$  del Bus-DC.

Por otro lado, el término de la función de coste que pondera el desequilibrio del Bus-DC a partir de  $\lambda_{DC}$  asegura la minimización del desequilibrio del Bus-DC para cualquier valor que tome  $V_{DC}$ . Por último, se observa una variación directa entre la frecuencia de conmutación y la tensión  $V_{DC}$ . Este hecho se debe a que con tensiones  $V_{DC}$  grandes, el margen que tiene el inversor para generar corrientes respecto a la tensión de red es mayor, y ello hace que el controlador realice un gran número de transiciones entre

estados de conmutación para regular y que no aumente la amplitud de la corriente. Estas conmutaciones por su parte, aumentan la frecuencia de conmutación de los IGBT. En cambio, para una  $V_{DC}$  baja, el inversor tiene mayor dificultad para mantener la potencia entregada a la red, y el controlador debe mantener más tiempo las tensiones a la salida, y por tanto no realizar tantas conmutaciones entre estados.




Figura 33. Generación de corrientes con un inversor 3L-NPC con  $V_{DC} = 540V$  y tensión máxima de red eléctrica 320V.

#### 2.4.4 Tensión de red

La red eléctrica considerada es trifásica, y por tanto compuesta por 3 tensiones alternas que se han denominado  $e_a$ ,  $e_b$  y  $e_c$ , de módulo  $|e|$  VAC rms. Se va a considerar que además están en una disposición en “estrella”, por lo que existe un punto de referencia denominado “punto neutro”. En cuanto a sus fases, considerando la  $e_a$  como referencia y por consiguiente con un desfase  $0^\circ$ ,  $e_b$  y  $e_c$  estarán desfasadas  $\pm 120^\circ$  y todas ellas son de frecuencia 50Hz. Los valores de las tensiones de red se consideran como una perturbación para el algoritmo de control MPC. Sin embargo, como se ha podido ver, su funcionamiento depende en gran medida de estos valores, principalmente al realizar la predicción de corrientes como se vio en [ 7], y para la generación de las consignas o corrientes de referencias del sistema visto en [ 29] y [ 30]. El diseño del algoritmo de control tiene en cuenta cierto nivel de tensión de red,

por tanto, si a posteriori su valor cambia o no se mantiene constante, puede llegar a provocar un mal funcionamiento de todo el convertidor.

En cuanto al funcionamiento propio del convertidor, los valores de las tensiones de red son de gran importancia, ya que como se deduce de lo visto en el apartado 2.4.1 y la Figura 25, el circuito eléctrico de cada fase hace que las corrientes dependan de dos tensiones, la de salida del inversor y la de la red eléctrica. Si la tensión de red es inferior a las tensiones de salida del inversor, se podrán generar correctamente las corrientes desde el inversor a la red, y su máximo dependerá de la impedancia entre ambas. Si por el contrario la tensión de red fuese superior a la de salida del inversor, no se podrían inyectar corrientes a la red eléctrica.

En los entornos de utilización de los convertidores 3L-NPC, la configuración de red eléctrica normalmente es en estrella, y la tensión nominal de red suele ser de unos 230 VAC rms medidos entre fase y el punto neutro, con una tensión de pico de unos 326V. Estas tensiones trifásicas, al convertirlas a ejes  $\alpha\beta$ , quedan finalmente con módulos de **400V**, por lo que en este trabajo se considerarán estos los valores normales de funcionamiento. Además, se considerará una secuencia positiva en la distribución de los desfases, tal como se muestra en la Figura 34 (a).

En cuanto a las posibles perturbaciones con origen en la red eléctrica, a continuación se describen los tipos más importantes, y se verá cómo responde el algoritmo MPC a cada uno de ellos.

- Cortes de Tensión: Según la norma UNE-EN 50160, existirá un corte de tensión cuando el valor de la tensión sea inferior a un 1% de la declarada, considerándose que existe una interrupción de la alimentación. Esta situación suele ser producida bien por incidencias con agentes externos (caídas, cortes, etc.) o bien por cortocircuitos debidos a sobretensiones.
- Huecos de Tensión: Según la misma norma UNE-EN 50160, se considera un hueco de tensión la disminución brusca de la tensión de red a un valor situado entre el 90% y el 1% de la declarada, producido durante un corto espacio de tiempo entre 10ms y 1min, seguido por el establecimiento de la misma. Los huecos de tensión pueden darse por descargas atmosféricas, contacto con animales y cortocircuitos entre otros. Existe una amplia clasificación de los huecos, en base al número de fases sobre las que se produzca la caída de la tensión, o si se conservan o no las fases de las señales.

- Sobretensión: Las sobretensiones pueden producirse también en la red eléctrica y sus efectos serán los contrarios a los que produzcan los huecos, por lo que no se profundizará en ello.

La presencia de huecos, cortes o reducciones bruscas de las tensiones de red, afectan en gran medida a las máquinas eléctricas o componentes conectados a la red, ya que cuando se producen, se alteran las corrientes que genera el inversor, y por tanto se verán afectadas las máquinas eléctricas conectadas a la red. Además, normalmente la terminación de la red eléctrica puede ser un transformador sobre el que se propagan los huecos. Aunque parezca que las tres ramas del convertidor son independientes, no hay que olvidar que el Algoritmo de Control Predictivo trabaja en componentes  $\alpha\beta$ , que dependen de todas las fases  $abc$  según las expresiones [ 2] y [ 3].

Para ver la influencia sobre el algoritmo MPC de los huecos o los cortes, se van a estudiar los efectos de dos casos concretos muy representativos: un corte de tensión de la fase  $b$  que afecta tanto a la componente  $\alpha$  como a la  $\beta$ , y un hueco de tipo A que se caracteriza por la disminución temporal de las tres tensiones a la vez conservando sus desfases (63). En las Figura 34 (b) y (c) se representan fasorialmente ambas situaciones respecto a los valores normales en (a).




Figura 34. Distribución de las componentes eléctricas trifásicas para el caso normal de funcionamiento (a), corte de tensión en la fase  $b$  (b) y un hueco de tipo A (c).

Considerando la aparición de un hueco de tipo A en la red eléctrica, de duración 40 ms, y con una profundidad de la bajada de un 20%, en la Figura 35 se muestra el efecto que tiene esta perturbación sobre la corriente de salida del convertidor.

Primeramente y como se observa, el tiempo de respuesta del inversor al generar las corrientes no es igual de abrupta que la aparición del propio hueco, ello se debe a la existencia del FSR-PLL como elemento sincronizador del sistema, que como se ha comentado ya, obtiene la componente de referencia  $e_q^+$  y se sincroniza con  $e_d^+$

haciéndola nula. El FSR-PLL introduce un transitorio que suaviza el hueco en la propia generación de las consignas  $i_\alpha^*$  e  $i_\beta^*$ , efecto que puede constatarse viendo la variación de la  $e_{q^+}$  y de las corrientes trifásicas de salida en la Figura 35.

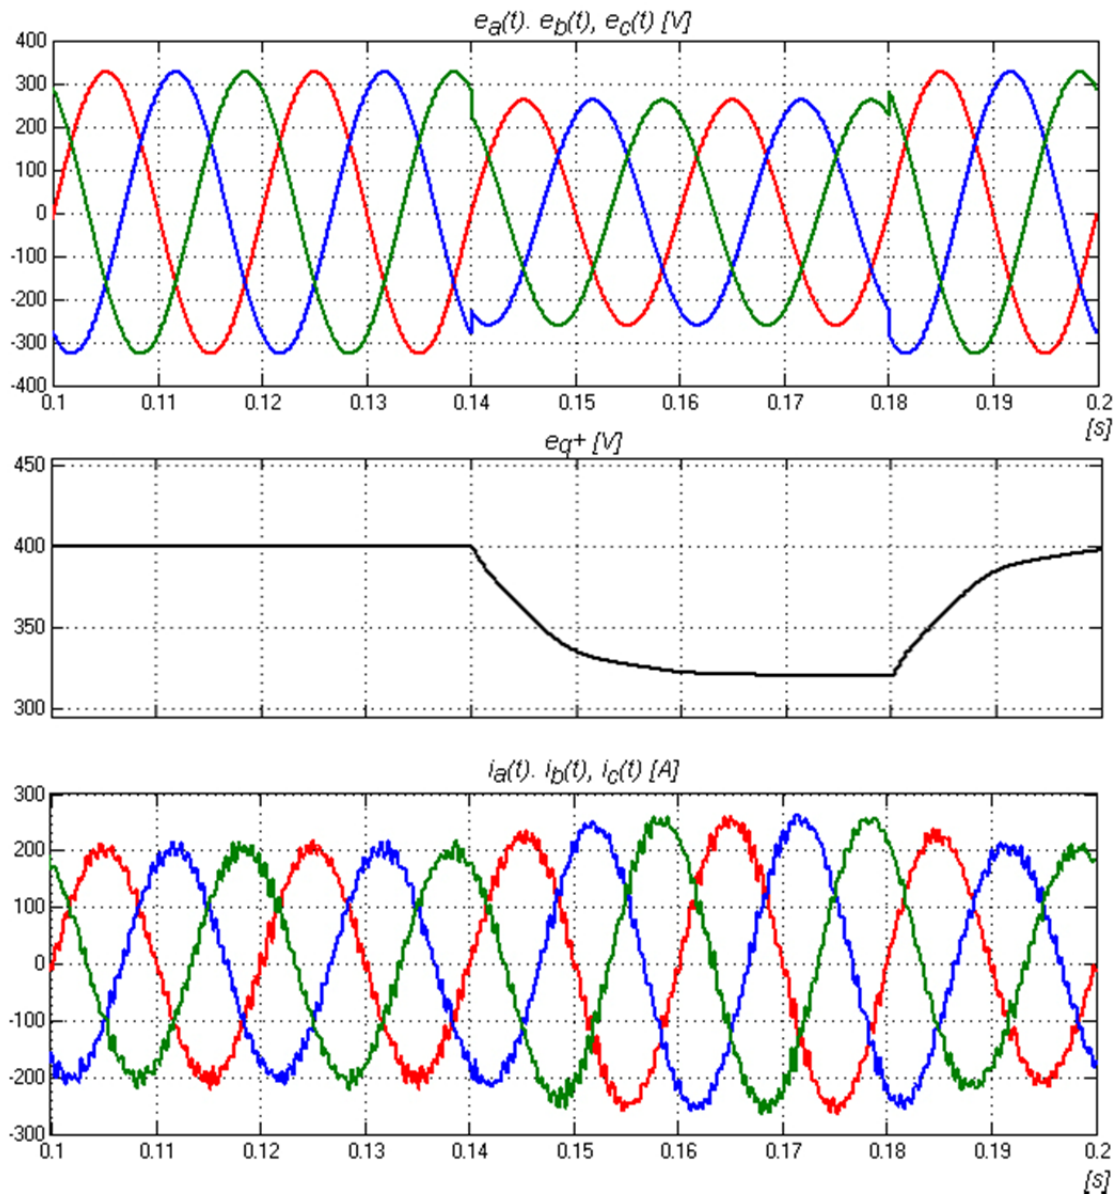


Figura 35. Respuesta del controlador MPC ante un hueco de tipo A en la red eléctrica de un 20% (0.8pu).

En segundo lugar, se ve como ante una bajada de las tensiones de red, las corrientes que se generan aumentan siguiendo la misma tendencia. Este hecho es debido a que para alcanzar las consignas de potencia  $P^*$  y  $Q^*$ , ante una reducción de la tensión de red, las corrientes inyectadas deben aumentar. En relación a la velocidad de respuesta, se puede concluir que el controlador MPC reacciona bien ante los huecos de la red, y la inclusión de un bloque de sincronización PLL ayuda a suavizar en gran medida sus efectos. Para el caso concreto mostrado, se observa un transitorio o



tiempo de respuesta ante el hueco de aproximadamente 20 ms desde que se produce el mismo hasta que la componente  $e_{q+}$  del PLL se estabiliza, y por tanto también las corrientes de salida (durante un período de señal de 50 Hz). En cuanto a la magnitud del cambio, se observa que, dependiendo de la profundidad y duración del hueco, este puede provocar que se generen corrientes muy elevadas que pongan en peligro el convertidor o elementos conectados a la red. Para el ejemplo evaluado, con una reducción de las tensiones de red de un 20% (de 320V a unos 256V, 64 V de caída), se produce un aumento de la corriente de un 25% (de 200A a 250A). Este efecto debe controlarse, limitando la amplitud máxima de corriente que se puede generar el inversor.

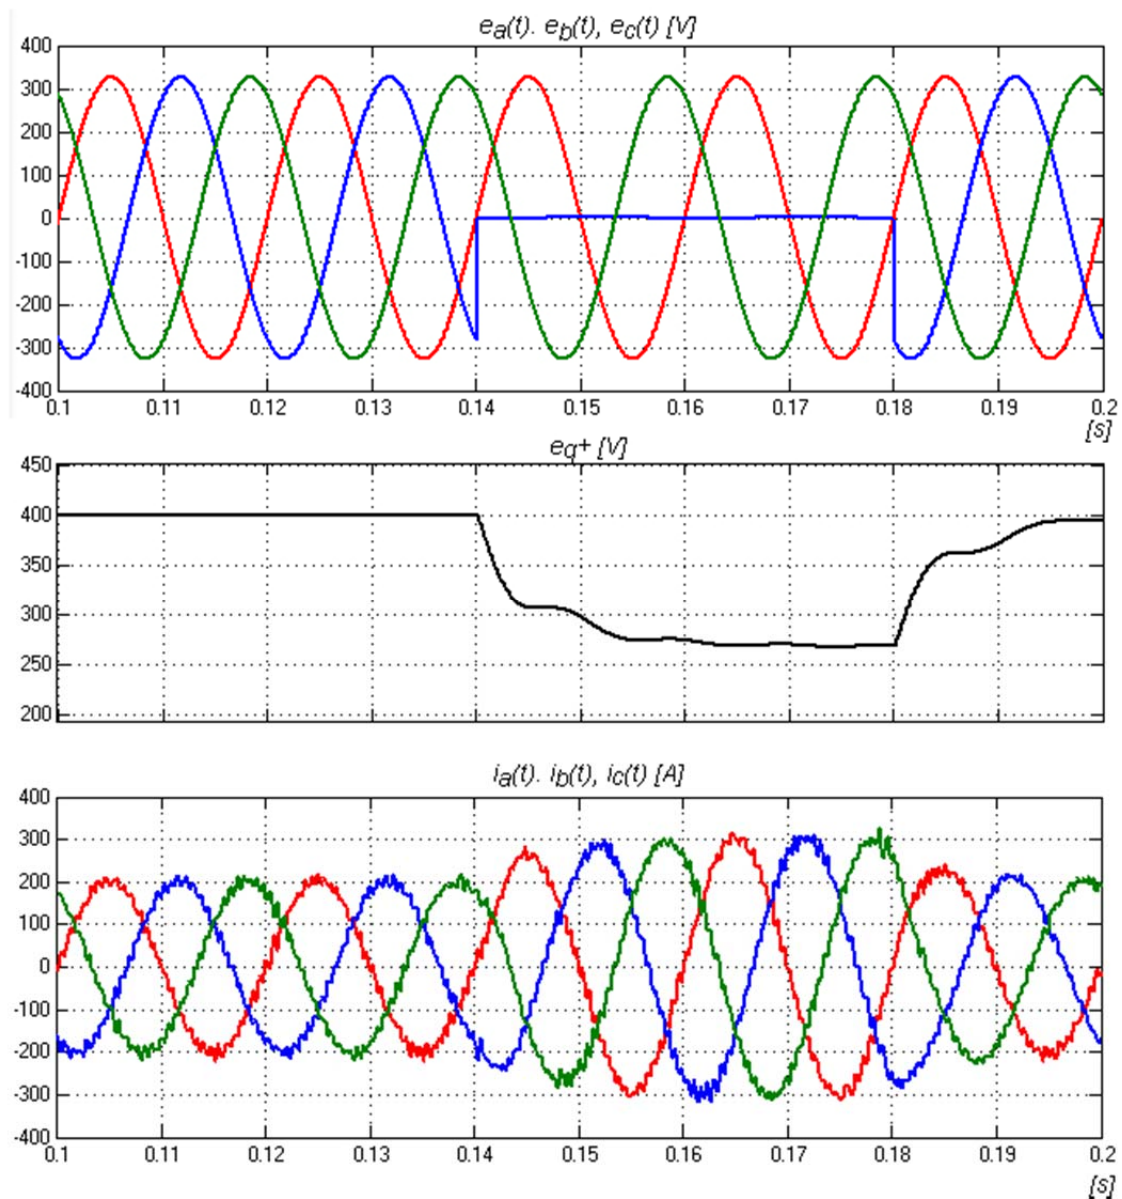


Figura 36. Respuesta del controlador MPC ante una caída de tensión de la fase  $b$ .



Para el caso de caída de alguna de las fases, como el mostrado en la Figura 36, el efecto es si cabe más notorio. La figura muestra el caso en el que existe una caída total de la fase  $b$  durante 40 ms, y como se puede ver los cambios son mayores respecto al caso anterior del hueco de tipo A. Por un lado, un cortocircuito en la fase  $b$ , afecta directamente a las tensiones  $e_\alpha$  y  $e_\beta$  con las que trabaja el controlador y a partir de las cuales se generan las corrientes de referencia. El efecto de la caída se aprecia en mayor medida en la componente de referencia  $e_{q+}$  implicada en el PLL, la cual sufre una reducción desde los 400V hasta unos 260V, un 35% o 140V de caída. Del mismo modo, se observa cómo en este segundo caso, las corrientes incrementan su valor desde los 200A hasta los 300A, suponiendo esta vez un aumento de un 50%. No obstante, en cuanto a la respuesta que tiene el controlador MPC, sigue siendo gradual con un tiempo de respuesta en torno a 20 ms como en el ejemplo anterior, y es capaz de adaptar las corrientes para mantener las consignas de potencia.

## 2.5 Tiempo de respuesta y respuesta en frecuencia del Algoritmo MPC

El funcionamiento del algoritmo MPC no solo se debe evaluar en régimen permanente, atendiendo al error de seguimiento de las referencias, sino que también se debe evaluar la respuesta transitoria ante un cambio de consignas. Así mismo, deben cuantificarse los armónicos que se introducen en la red. Por ello, a continuación, se realiza estudio en el dominio del tiempo y la frecuencia del Algoritmo de Control Predictivo aplicado a un inversor 3L-NPC.

### 2.5.1 Tiempo de respuesta del algoritmo MPC

La respuesta temporal del algoritmo de Control Predictivo, dependerá del ajuste del controlador, de la implementación que se lleve a cabo, del hardware sobre el que se implemente y de la frecuencia de funcionamiento del mismo. Como ya se ha indicado, en esta tesis se va a usar una tarjeta FPGA para realizar la implementación del algoritmo.

En este trabajo, se ha considerado la implementación del algoritmo MCP como el realizado en (42), en el que el controlador se desarrolló íntegramente en lenguaje VHDL y las pruebas realizadas se han hecho con la siguiente configuración:

Tensión Bus-DC	$V_{DC}=800V$
Tensión de red eléctrica	$e = 230 \text{ V rms}$

Período de muestreo	$T_s = 100\mu s$
Resistencia nominal del filtro	$R = 0.063 \Omega$
Inductancia nominal del filtro	$L = 2 \text{ mH}$
Max. Potencia del convertidor	100 kVA
Referencia de potencia activa	$P^* = 100 \text{ kW}$
Referencia de potencia reactiva	$Q^* = 0 \text{ kVAr}$
Factor de peso del desequilibrio Bus-DC	$\lambda_{DC} = 1.2$
Factor de peso de la freq. de conmutación	$\lambda_{SW} = 1$
Tarjeta de desarrollo	Xilinx ZC702
Velocidad de reloj	50 MHz (20 ns)
Tamaño de los datos (en punto fijo)	18 bits

Según las pruebas realizadas, en cuanto al tiempo de cómputo del algoritmo MPC, que incluye desde la lectura de nuevas muestras, hasta que se fija el siguiente estado de conmutación, resulta ser de **2.8 $\mu s$** . Además, debido a que es un tipo de implementación de bajo nivel (implementación hardware), que siempre realiza las mismas operaciones de forma síncrona, se puede asegurar que, si el tiempo entre muestras  $T_s$  es invariante, el resultado del control siempre se obtendrá en el mismo instante de tiempo (2.8 $\mu s$  después de que lleguen las muestras), si bien es cierto que como en todos los sistemas digitales, puede haber pequeñas fluctuaciones debidas a ruidos de fase o *jitters* que provoquen retrasos en las señales. No obstante, en el caso de que se produzcan, serán del orden de magnitud de la frecuencia de reloj de la FPGA, que en este caso es de 20 ns.

En la Figura 37 se muestra un ejemplo de cálculo del tiempo que transcurre desde que se comienza a ejecutar el controlador, hasta que termina su proceso y fija un nuevo estado de conmutación, este intervalo es lo que denominaremos “ciclo de proceso”. El tiempo de ejecución resulta de **140 ciclos** de reloj, o 2.8 $\mu s$  si  $f_{clk}=50\text{MHz}$ .

Las señales mostradas en el cronograma son las siguientes:

- *clk*: señal de reloj de 20 ns.
- *start\_control*: señal de control de entrada por flanco de subida que indica al controlador que tiene nuevos datos y comienza un nuevo ciclo de proceso.
- *rdy\_control*: señal de indicación de salida para indicar que se ha terminado un ciclo de proceso y se puede configurar un nuevo estado.
- *state\_reg*: estado de conmutación en el que está o se fija al inversor 3L-NPC.

- *Valpha* y *Vbeta*: señales de las tensiones de salida del inversor en componentes  $\alpha\beta$  (las que obtiene y ve el controlador). Estas señales actualizan sus valores justo después de terminar el ciclo de proceso.
- *ialpha\_ref*: corriente  $i^*\alpha$  generada internamente en el controlador. Cuando se termina el ciclo de proceso, se configura al inversor en el estado que minimice la función de coste anteriormente definida.
- *ialpha\_k*: muestra de corriente  $ia(k)$ , que como se observa, se toma siempre que comience un ciclo de proceso.

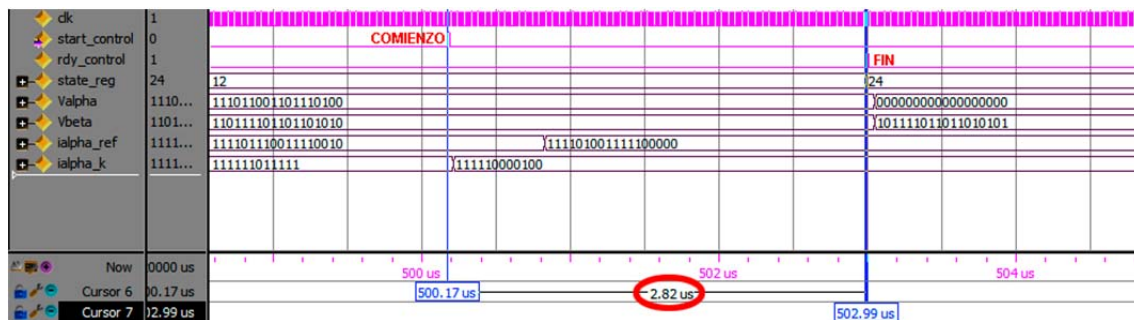


Figura 37. Medición del tiempo de ejecución de un ciclo del algoritmo MPC.

Como se comentó en el CAPÍTULO 1, el hecho de utilizar una implementación del algoritmo de Control Predictivo basado en FPGA, conlleva una serie de ventajas en cuanto al tiempo de respuesta. Primeramente, con las FPGA los tiempos de ejecución de los distintos procesos están fuertemente acotados y la ejecución de los bloques se realiza de forma concurrente, mientras que con sistemas DSP la ejecución debe ser secuencial y pueden surgir variaciones debidas a retrasos en los procesos, accesos a memoria o interrupciones que interrumpan el flujo de operación. Otra peculiaridad, es que la implementación en FPGA permite aplicar el estado de conmutación durante el mismo intervalo de muestreo, sin necesidad de esperar a la siguiente muestra, como ocurre con otras técnicas de control. Debido a que la implementación hardware en FPGA usando VHDL es concurrente, cada proceso se activa por separado sin tener que seguir una secuencia como en el caso de los DSP, que no podrían aplicar el estado nuevo hasta el siguiente intervalo de muestreo que es cuando se actualizan los valores de las señales, teniendo una latencia de 1 ciclo en la aplicación del mismo. Esto quiere decir que el controlador basado en FPGA, puede rápidamente corregir el estado de conmutación del inversor y cuando le lleguen las siguientes muestras, ya habrá dado tiempo a que se produzcan los cambios en el inversor y en las corrientes. De esta forma, cuando llegan las nuevas muestras, el controlador sabrá si el estado

que configuró en el estado anterior, provocó una mejora o un empeoramiento del seguimiento de las corrientes.

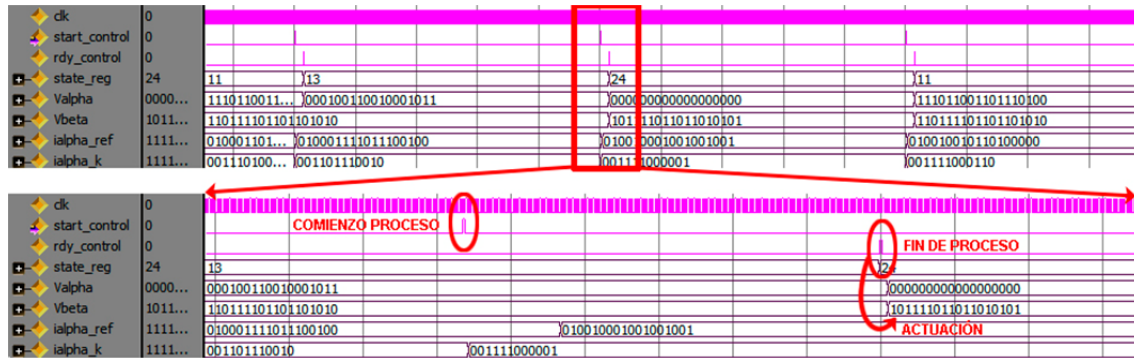


Figura 38. Marcas de inicio de ejecución y fin de ejecución de un ciclo de control y actuación del controlador.

La Figura 38 muestra un ciclo de proceso del controlador. Una vez completado dicho ciclo, se genera un flanco en la señal `rdy_control`; instantes después, cambian las tensiones  $V_\alpha$  y  $V_\beta$  y por tanto también las salidas del inversor  $V_{A0}$ ,  $V_{B0}$  y  $V_{C0}$ , y con ellas las corrientes  $i_a$ ,  $i_b$  e  $i_c$ . Como se observa, la actuación se produce antes de la siguiente muestra.

En cuanto a la respuesta dinámica del modelo, se ha realizado un experimento para medir el tiempo de actuación del algoritmo MPC ante un cambio de referencias. Con este fin, se ha considerado un modelo de planta diseñado en Simulink con un valor de inductancia de 10mH, con el algoritmo MPC ejecutado sobre la FPGA donde se ha implementado. Esta técnica es la conocida como “*hardware in the loop*”, que permite comprobar modelos implementados en hardware, mientras su entorno o planta pueden generarse libremente desde Simulink, en este caso usando la toolbox *Sim Power System*, que permite modelar el convertidor, la red eléctrica, el filtro y el bus-DC. El objetivo final, es poder medir el tiempo de reacción del algoritmo, por lo que se probó un escalón de consigna “agresivo”, equivalente a pasar de unas corrientes de 75A a 150A, y posteriormente uno “suave” de los 150A a los 120A.

La Figura 39 muestra el resultado, donde se observa que la respuesta del algoritmo ronda los 7ms en un caso y apenas los 5ms en el otro.




Figura 39. . Respuesta dinámica del algoritmo MPC ante un cambio de consignas.

Para analizar la respuesta temporal completa del inversor controlado por MPC, se ha realizado un experimento en el que se ha provocado un cambio en las consignas de potencia en forma de escalón. Concretamente se ha analizado un caso en el que solo se demanda potencia activa ( $Q^*=0$ ), en el que  $P^*$  pasa de 0kW a 100kW, siendo estas la mínima y máxima potencia respectivamente. Para evaluar la respuesta ante este escalón, se ha realizado el análisis observando las corrientes de referencia y las generadas en ejes dq, al ser estos valores constantes en vez de sinusoidales como en el caso de representarlos en ejes  $\alpha\beta$ . Usando los mismos valores de configuración del sistema antes descritos, con una tensión de red de 230V rms correspondientes a 400V en ejes dq, un escalón de 0 a 100kW en  $P^*$ , equivale a uno de 0 a 250A en  $i_q^*$  ( $i_d^*=0$  al ser  $Q^*=0$ ).

La Figura 40 muestra la relación entre la corriente de referencia  $i_q^*$  y la que se genera en el sistema  $i_q$ , obteniéndola mediante las corrientes  $i_\alpha$ ,  $i_\beta$  y la fase de la tensión de red obtenida por el FSR-PLL. Analizando la respuesta, vemos como presenta un comportamiento sobre-amortiguado, con un tiempo de respuesta de aproximadamente 2 ms, lo cual confirma la rápida respuesta del algoritmo MPC, y una respuesta transitoria adecuada, que no presenta sobre-impulso.




Figura 40. Respuesta del algoritmo MPC ante un cambio de consigna de  $P^*$  desde 0 a 100kW analizando la corriente de referencia  $i_q^*$ , y la generada  $i_q$ .

### 2.5.2 Respuesta en frecuencia

Al igual que todos los sistemas conmutados, el convertidor utilizado en esta tesis es susceptible de generar armónicos en las corrientes de salida. Esto quiere decir, que aunque la frecuencia fundamental de estas sea de 50 Hz, debido a las transiciones entre estados y por tanto conmutaciones de los IGBT, cuyo período de cambio está gobernado por el período de muestreo  $T_s$ , se generarán componentes de frecuencias múltiplos de la fundamental o armónicos, así como ruidos de alta frecuencia. La introducción de estas componentes frecuenciales se traduce en degradaciones de las propias señales, llegando a afectar en gran medida al seguimiento de las referencias o *tracking*. Cuando hay armónicos no deseados en las corrientes de salida, las señales finales resultan de la suma de la componente fundamental y de todos los armónicos presentes, causados por los elementos no lineales que actúen en el proceso. Realizar un análisis exhaustivo de la respuesta en frecuencia del algoritmo MPC es complicado de abordar (15), ya que no es un algoritmo de control lineal sobre el que se puedan aplicar los conceptos tradicionales y teóricos de ancho de banda. Por ello, se ha optado en esta tesis por realizar un análisis basado en resultados experimentales.

Entre los efectos más destacados que puedan provocar los armónicos y por tanto hacen que sea muy importante mitigarlos en la medida de lo posible, se encuentran:

- Resonancia: cuando existen dispositivos capacitivos y/o inductivos presentes en los sistemas de distribución que estén en presencia de armónicos, puede ocurrir el fenómeno de la resonancia, dando impedancias resultantes bajas o altas respecto a la nominal, que a su vez modifican las propias corrientes que se generan y el funcionamiento del inversor, como ya se ha visto.
- Aumento de las pérdidas de potencia: Cuando hay armónicos presentes en las corrientes, sus valores eficaces son superiores al fundamental, y ello hace que aumenten las pérdidas por efecto Joule en conductores y transformadores, así como pérdidas en máquinas síncronas por la circulación de corrientes de frecuencia mayor.
- Sobretensiones: Por la propia definición de las corrientes o tensiones como suma de una fundamental más sus armónicos, existirá un factor de cresta que puede provocar sobretensiones en equipos como los SAI.

El método más inmediato para evaluar el comportamiento en frecuencia de un sistema, es observar el espectro de las señales de interés. Así mismo, para evaluar la aparición de armónicos múltiplos de la frecuencia fundamental, se evalúa la distorsión armónica total o THD que cuantifica la relación en potencia que existe entre la suma de los armónicos y la componente fundamental. Un THD elevado, indica que los armónicos son también elevados respecto a la fundamental, y viceversa.

En el caso del inversor 3L-NPC controlado por el algoritmo MPC, los máximos responsables de la distorsión armónica son las conmutaciones de los IGBT. En los apartados anteriores, se han mostrado los efectos que producen ciertas variaciones de parámetros sobre el THD, y sobre la frecuencia de conmutación de los IGBT. A continuación se mostrará un ejemplo de análisis del espectro en frecuencia de las corrientes de salida con el sistema trabajando con la siguiente configuración:

Tensión Bus-DC	$V_{DC}=800 \text{ V}$
Tensión de red eléctrica	$e = 230 \text{ V rms}$
Período de muestreo	$T_s = 100\mu\text{s}$
Resistencia nominal del filtro	$R = 0.063 \Omega$
Inductancia nominal del filtro	$L = 2 \text{ mH}$
Max. Potencia del convertidor	100 kWA
Referencia de potencia activa	$P^* = 100 \text{ kW}$
Referencia de potencia reactiva	$Q^* = 0 \text{ kVAr}$
Factor de peso del desequilibrio Bus-DC	$\lambda_{DC} = 1.2$

Factor de peso de la freq. de conmutación	$\lambda_{sw} = 1$
---	--------------------

La Figura 41 muestra el espectro de frecuencia de la corriente  $i_a(k)$  con el sistema configurado con los datos anteriores, en unidades naturales  $w$ . Como se observa, la componente frecuencial de 50 Hz es la componente fundamental de la señal. No obstante, aparecen ciertas componentes de mayor frecuencia, aunque en este caso no afectan en gran medida a la THD. Para poder apreciar mejor la relación entre la componente fundamental de 50 Hz y los armónicos presentes, la Figura 42 muestra el espectro de frecuencia en escala logarítmica.




Figura 41. Espectro de frecuencia en unidades naturales de la corriente  $i_a(k)$  generada por un inversor 3L-NPC con  $f_s=10\text{kHz}$  y la configuración expuesta.






Figura 42. Espectro de frecuencia en unidades de dB de la corriente  $i_a(k)$  generada por un inversor 3L-NPC con  $f_s=10\text{kHz}$  y la configuración expuesta.

La Figura 43 muestra el mismo caso anterior, pero ampliando la región donde aparecen los efectos no deseados para poder ver mejor los pesos que tienen estas componentes. Además, se acompaña junto a la respuesta en frecuencia, una muestra de la propia señal  $i_a(k)$  y se han calculado los índices de calidad del sistema. Se puede ver claramente cómo las componentes de más amplitud, están en torno a la frecuencia media de conmutación de los IGBT, que en este caso está en torno a los 1.7kHz. Por tanto, podemos concluir que la mayor distorsión que se producirá en frecuencia usando algoritmo MPC, es debida a la frecuencia de conmutación de los IGBT.

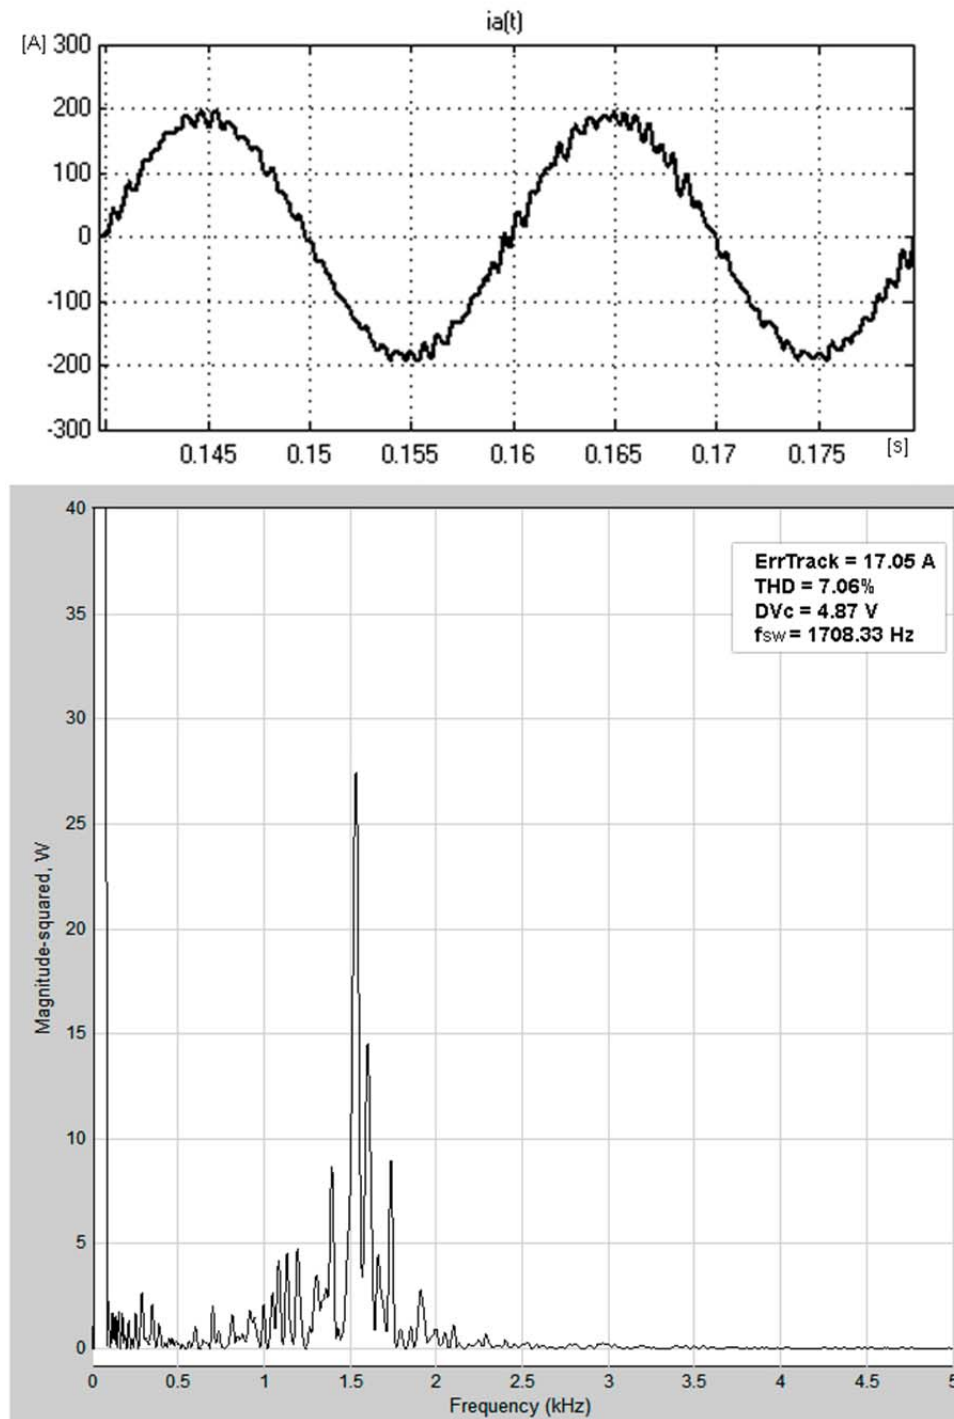


Figura 43. Región ampliada de las principales distorsiones encontradas en frecuencia sobre la corriente  $ia(k)$ , y muestra de la señal.

## 2.6 Conclusiones

Resumiendo los objetivos de control, formalizados como distintos términos de la función de coste, ya analizados en el capítulo 2, se pueden establecer las siguientes conclusiones:

- **Seguimiento de las consignas de corriente (tracking):** Es el término fundamental de la función de coste del controlador MPC, y es el que, en cualquier circunstancia, el algoritmo debe priorizar, ya que es el principal objetivo de control: que el error de seguimiento de las referencias de corriente sea mínimo. Por tanto, el *tracking* estará influenciado directamente por las consignas  $P^*$  y  $Q^*$ . Debido a todo esto, este término aparece en la función de coste del controlador MPC, con un peso de ponderación de 1.
- **Desequilibrio del Bus-DC:** Como se ha evidenciado, el Bus-DC aporta la energía y niveles de tensión al inversor y resulta de gran importancia en la generación de las corrientes. Si aumenta el desequilibrio, las tensiones en los puntos P y N pueden aumentar superando  $V_{DC}/2$  y poniendo en riesgo la integridad de los IGBT. Las causas del desequilibrio son fundamentalmente dos: los estados de conmutación en los que se configura el inversor, ya que de ellos dependerá la corriente  $i_o$  que lo provoca; y t la amplitud de las corrientes que se generen, ya que  $i_o$  puede tomar los valores de  $i_a(k)$ ,  $i_b(k)$  e  $i_c(k)$ , cuya amplitud dependerá en última instancia de  $P^*$  y  $Q^*$ . Así mismo, al no estar equilibradas la tensiones, se generan distorsiones en las corrientes que provocan más transiciones entre estados al intentar el controlador realizar correcciones.
- **Frecuencia de conmutación de los IGBT:** Durante el funcionamiento del controlador, se configura al inversor para funcionar en diferentes estados, que implican conmutaciones de los IGBT que conforman las ramas. El número de conmutaciones dependerá del valor de las corrientes a generar, y por tanto de las consignas  $P^*$  y  $Q^*$ . Un aumento de las mismas reduce la eficiencia en potencia del convertidor, debido al aumento de las pérdidas térmicas. Además, al aumentar la frecuencia, aparecen armónicos de alta frecuencia añadidos a la componente principal de 50Hz.

- **Filtro de red:** Las variaciones de  $R$ , aunque influyen en el error de seguimiento de las consignas de corriente, suponen un error en torno al 0,5% para una desviación de  $\pm 20\%$  en torno al valor nominal considerado, y por tanto son asumibles. En cambio, como se ha visto, cuando se produce una reducción de la inductancia  $L$  respecto al valor nominal considerado en el modelo, factores tan importantes para el funcionamiento del controlador como el error medio de *tracking* y el THD empeoran. Compensar este efecto no es trivial. No obstante, no es habitual que  $L$  tenga una tolerancia elevada, por lo que sus efectos negativos sobre la respuesta del controlador podrán acotarse.
- **Período de muestreo:** El tiempo entre muestras de las señales  $T_s$ , que será por tanto el tiempo disponible que tiene el controlador MPC para aplicar el nuevo estado, es un valor que se considerará impuesto por la implementación digital del algoritmo, aunque como ya se demostró en el anterior capítulo, las prestaciones del controlador dependen de su valor.
- **Tensión del Bus-DC:** La tensión del Bus-DC tiene una gran importancia en el funcionamiento del sistema, sin embargo, su margen de cambio es amplio en cuanto a los efectos dañinos que produce, ya que para que se vean afectados los parámetros de calidad del inversor, la tensión  $V_{DC}$  debe caer hasta valores próximos al doble de la tensión de red. Se fijará su valor dependiendo de la capacidad del rectificador, de los componentes eléctricos del Bus-DC y del propio inversor, estando siempre alejado del punto crítico en el que  $V_{DC}/2$  sea igual o inferior a la tensión de red. De igual forma, se ha mostrado como una tensión  $V_{DC}$  alta puede aumentar la frecuencia de conmutación de los IGBT, por lo que hay que tener en cuenta esta relación como una cota superior. La tensión del Bus-DC  $V_{DC}$  será pues un valor prefijado, del cual se asumirá también una posible variación sin que afecte en gran medida al sistema.
- **Tensión de red:** La tensión de red puede considerarse como una perturbación para el sistema de control. Sin embargo, el bloque de sincronización FSR-PLL con que cuenta el controlador, permite minimizar los efectos de pequeña duración que se produzcan. En caso de que exista una caída de tensión o un problema a largo plazo, no resulta conveniente que el propio convertidor siga funcionando. Así pues, el propio FSR-PLL será el mecanismo implícito con el

que cuenta el algoritmo MPC para corregir perturbaciones de corta duración en las tensiones de red.

- **Respuesta en Frecuencia:** El controlador puede provocar cierta distorsión armónica, y lo que es peor aún, armónicos de orden elevado. Por ello resulta conveniente incluir la eliminación selectiva de los armónicos no deseados, tal como se hace en trabajos como (7), de tal manera que, para cada uno de los estados de conmutación posibles, se calcule cual produce menor distorsión armónica y que este efecto entre a formar parte de la función de coste. Sin embargo, para calcular anticipadamente la distorsión armónica total empleando técnicas digitales, se necesitaría calcular la transformada de Fourier de la posible señal de salida, para cada uno de los 27 estados, lo que implica una cantidad elevada de recursos y tiempo. La alternativa que se propone en esta tesis es realizar un estudio sobre el comportamiento del sistema, evaluando el THD para distintos ajustes de la función de coste, con el fin de elegir los valores de ponderación que implícitamente generen menor THD.

# **CAPÍTULO 3. PROPUESTA DE ALGORITMO DE CONTROL PREDICTIVO ADAPTATIVO O A-MPC**

En el anterior capítulo, se ha analizado y caracterizado el Control Predictivo sobre un convertidor 3L-NPC. Se han puesto de manifiesto las ventajas e inconvenientes que ofrece, y se ha analizado su sensibilidad ante la variación de ciertos parámetros. Gracias a su formulación simple, el control predictivo de convertidores multinivel está muy extendido y se pueden encontrar numerosos trabajos en la bibliografía. Sin embargo, sigue siendo campos de investigación abierta, tanto los métodos de ajuste de la función de coste, como el aumento de su robustez, para hacerlo más insensible a las perturbaciones e incertidumbres de modelado.

Una vez analizados los objetivos de control y la sensibilidad del controlador a distintos parámetros, se propondrá una metodología de optimización para disminuir la sensibilidad a las incertidumbres de modelado y a las posibles perturbaciones. La solución propuesta consiste en adaptar los pesos de los diferentes términos de la función de coste, para alcanzar los objetivos de control, optimizando ciertos índices de calidad, de ahí que se haya denominado al nuevo esquema algoritmo MPC adaptativo, A-MPC en adelante.

## **3.1 Índices de calidad del sistema**

Para poder evaluar el comportamiento del sistema, se definen primeramente ciertos índices de calidad, que ayuden a cuantificar el buen o mal funcionamiento de este, respecto a los objetivos de control. A continuación se definen los índices de calidad o figuras de mérito que se han empleado en esta tesis, todos ellos calculados siempre como valores medios a lo largo de un período de muestreo de las señales.

### 3.1.1 Error medio de tracking

Es el índice de calidad más importante del sistema, ya que cuantifica el error entre las corrientes de salida y las de referencias. Esta desviación, se obtiene como la media de la desviación en el plano  $\alpha$  y en el plano  $\beta$ , sobre los cuales trabaja el algoritmo de Control Predictivo, pudiéndose expresar formalmente como:

$$Error\ medio\ de\ tracking = \Delta i_{\alpha\beta} = \frac{1}{N} \sum_k \frac{|i_{\alpha}^*(k) - i_{\alpha}(k)| + |i_{\beta}^*(k) - i_{\beta}(k)|}{2} \quad [47]$$

siendo  $i_{\alpha}^*(k)$  e  $i_{\beta}^*(k)$  las corrientes de referencia, mientras que  $i_{\alpha}(k)$  e  $i_{\beta}(k)$  son las corrientes reales generadas obtenidas tras aplicar el Algoritmo de Control Predictivo, pero convertidas también a componentes  $\alpha\beta$ . Las etiquetas 'k' representan cada una de las muestras en un período  $T_s$ , sumando un total de 'N' muestras.

La explicación de porqué realizar una media entre ambas componentes, en vez de calcular las desviaciones por separado, es que son dos corrientes que guardan cierta relación entre ellas y por tanto no son totalmente independientes. Este hecho se constata directamente si se tienen en cuenta las expresiones que se usan para pasar de componentes  $abc$  a  $\alpha\beta$  [2][3], donde tanto  $i_{\alpha}$  como  $i_{\beta}$  dependen de  $i_b$  e  $i_c$ . Esto quiere decir que un problema o efecto negativo en estas dos fases, se traslada directamente a  $i_{\alpha}$  y a  $i_{\beta}$ . Solamente se da el caso en que  $i_a$  está involucrada en la transformación a  $i_{\alpha}$  y no en  $i_{\beta}$ , no obstante, salvo una caída de tensión o hueco en  $e_a(t)$ , o un cambio en algún elemento eléctrico implicado en el circuito de esta fase, el funcionamiento del convertidor va ser prácticamente idéntico en todas ellas.

Otro aspecto a la hora de evaluar el error de tracking, es que no parece recomendable utilizar errores relativos (como por ejemplo en porcentajes de desviación) por dos motivos muy importantes. Primeramente, porque tanto si se quiere evaluar el error desde la función de coste o como una media del error en sí ( $\Delta i_{\alpha\beta}$ ) en unidades relativas, se debería realizar una operación de división, como por ejemplo  $i_{\alpha}(k)/i_{\alpha}^*(k)$ . Las operaciones de división con números no enteros son difícilmente implementables en hardware, y mucho menos en formato de punto fijo como se hará en esta tesis. Por otro lado, asumiendo que se pudiesen calcular los errores de forma *offline*, tanto las corrientes reales generadas ( $i_{\alpha\beta}(k)$ ) como las referencias ( $i_{\alpha\beta}^*(k)$ ) son dependientes del tiempo y sus valores varían sinusoidalmente. Ello implica que si se calculasen errores relativos se realizaría una sobre-ponderación cuando las referencias tomen valores

próximos a cero. Por ejemplo, considérese el caso en el que en cierto instante  $k$ ,  $i_{\alpha}^*(k)$  vale 200A, pero la  $i_{\alpha}(k)$  obtenida fue 200,19A, en este caso el error relativo sería de  $|i_{\alpha}^*(k) - i_{\alpha}(k)|/i_{\alpha}^* = 0,00095 = 0,095\%$  y el error absoluto de 0,19A. Considérese a continuación otro cierto momento en el que  $i_{\alpha}^*(k)$  sea 0,05A y que  $i_{\alpha}(k)=0,24A$ . Para este caso  $|i_{\alpha}^*(k) - i_{\alpha}(k)|/i_{\alpha}^* = 3,8 = 380\%$  mientras que el error absoluto sería el mismo, 0,19A. Un error de 0,19A cuando la referencia esté próxima a cero puede ser despreciable si el orden de las corrientes es de cientos de amperios, en cambio con errores relativos sobre corrientes que van modificando su valor y pasan por cero, puede variar considerablemente su percepción.

Por todo ello, y asumiendo la dependencia entre ambas corrientes, se ha decidido usar la desviación media entre ambas como índice de calidad para evaluar el seguimiento de las corrientes de referencia por parte del algoritmo MPC.

### 3.1.2 Distorsión armónica total media

La distorsión armónica total o THD de una señal, se define formalmente como la relación que existe entre la potencia total de todas las componentes de frecuencia múltiplos de la fundamental, en relación con la potencia de dicho armónico principal o frecuencia fundamental  $f_0$ . Es pues, un índice de calidad que cuantifica el grado de distorsión de una señal debido a la presencia de componentes de frecuencia no deseadas. El THD se define como:

$$\begin{aligned} \text{Distorsión armónica total} = THD &= \frac{\sum \text{Potencia de los armónicos}}{\text{Potencia de la frecuencia fundamental}} \\ &= \frac{\sum P(kf_0)}{P(f_0)} \end{aligned} \quad [48]$$

Como las señales más importantes en el funcionamiento del convertidor son las corrientes generadas  $i_a$ ,  $i_b$  e  $i_c$ , y pasadas a componentes  $\alpha\beta$ ,  $i_{\alpha}$  e  $i_{\beta}$  (para trabajar en el mismo ámbito que el controlador), el cálculo del THD del sistema se debe evaluar sobre estas mismas señales. Teniendo en cuenta la misma consideración que para el caso de los errores de *tracking*, donde se consideró que existe siempre cierta dependencia de las corrientes en componentes  $\alpha\beta$ , el índice de calidad que se utilizará finalmente será la distorsión armónica total media de las dos fases durante todo un período  $T_s$ , al que, por simplicidad, denominaremos como el **THD** del convertidor y se definirá como:



$$Distorsión armónica total media = THD = \frac{THD\alpha + THD\beta}{2} \text{ durante } Ts \quad [49]$$

De esta manera, con un único índice se puede cuantificar la respuesta en frecuencia sobre las tres fases.

Este índice, como se ya se ha explicado, no está presente en la función de coste y por tanto el controlador MPC no lo calcula en tiempo real. Por ello, se ha realizado un estudio *offline* de la relación entre THD con las consignas  $P^*$  y  $Q^*$  y con diferentes factores de peso  $\lambda_{DC}$  y  $\lambda_{SW}$ . Así posteriormente, si se establece como objetivo de control limitar el THD a cierto valor, se conocerá qué configuración  $P^*$ ,  $Q^*$ ,  $\lambda_{DC}$  y  $\lambda_{SW}$ , se podría usar para ajustar el controlador y que se respete dicho umbral.

Para calcular los THD de cada fase, se han utilizado bloques de *Simulink*, *Xilinx System Generator* o funciones en MATLAB, sobre colecciones de muestras de las 3 corrientes, previo de una transformación a componentes  $\alpha\beta$ .

### 3.1.3 Desequilibrio medio del Bus-DC

El desequilibrio del Bus-DC será un índice usado para cuantificar la variación de voltaje de este bus cuando se producen transiciones de un estado a otro. En estos casos, se crea una corriente en el punto neutro del convertidor  $i_o$ , que hace que las tensiones que se tengan en ambos condensadores del bus no sean iguales, y por tanto se desvíen cierto valor  $\Delta V$ . En la Figura 44 se representa gráficamente la diferencia entre un Bus-DC equilibrado y otro en el que se ha producido un desequilibrio. Este índice de calidad se va a obtener de la misma manera que el algoritmo MPC lo obtiene internamente durante su funcionamiento según la expresión [37], para aplicarlo posteriormente a su función de coste, es decir, como  $|\Delta V_c| = |V_{C1} - V_{C2}|$




Figura 44. Representación del desequilibrio del Bus-DC

Como ya se ha explicado, si se ven afectados los niveles de tensión de las referencias del inversor, es decir  $+V_{DC}/2$  y  $-V_{DC}/2$ , también se verán afectados los niveles de tensión a su salida, y por ende las corrientes que se generarán. El desequilibrio medio del Bus-DC, se calculará a partir de las muestras de tensión de los dos condensadores que lo componen y se calculará la media temporal para obtener un único índice de calidad. Formalmente, la expresión que definirá esta figura de mérito será:

$$\begin{aligned} \text{Desequilibrio medio del Bus} - DC = \Delta V_c &= \frac{1}{N} \sum_k |V_{C1}(k) - V_{C2}(k)| \\ &= \frac{1}{N} \sum_k \Delta V(k) \end{aligned} \quad [50]$$

### 3.1.4 Frecuencia media de conmutación de los IGBT

Esta magnitud se define como la frecuencia a la cual conmutan los IGBT del inversor 3L-NPC, y como se ha visto en apartados anteriores, tiene una gran importancia en cuanto al comportamiento en frecuencia del sistema, la integridad de las señales y el rendimiento en potencia del convertidor. Aunque el algoritmo MPC la incluye directamente en su función de coste, para obtenerla no realiza una medición real de la frecuencia de conmutación. Debido a que los IGBT son elementos que son configurados digitalmente, el controlador que es el encargado de hacerlo, sabe por tanto que IGBT activa o desactiva para cada estado del convertidor, y por tanto puede conocer en cada momento cuantas transiciones se producen. El número de conmutaciones durante la transición del estado  $i$  a  $j$ , que hemos denominado  $Nc(i,j)$ , es un dato que el propio algoritmo de Control Predictivo conoce de ante mano y es totalmente determinista.

No obstante, para comprobar que la frecuencia de conmutación efectivamente se mantiene en los valores prefijados por la aplicación de la función de coste del controlador, se ha medido esta de manera externa al propio controlador. Para hacerlo, se ha usado un bloque que mediante las señales de control de los IGBT que el algoritmo genera, es capaz de obtener el número de cambios reales de un estado nuevo respecto al anterior configurado, y dividiendo este número entre el tiempo  $T_s$ , obtiene el número de cambios por unidad de tiempo, dando así la frecuencia de conmutación real. Para obtener el índice de calidad real, que denominaremos  $f_{sw}$ , se calcula la media temporal de todas las medidas puntuales de frecuencia. En la

siguiente figura se muestra un diagrama simplificado del medidor de la frecuencia de conmutación de los IGBT.




Figura 45. Esquema funcional del bloque de medición de la frecuencia de conmutación media de los IGBT del sistema.

La expresión para obtener la frecuencia media de conmutación de los IGBT se define como la suma del número total de conmutaciones por cada período de muestra  $T_s$ :

$$\text{Frecuencia media de conmutación} = f_{sw} = \frac{1}{T_s} \sum_k Nc(i, j, k) \quad [51]$$

### 3.2 Modelo propuesto: Algoritmo de Control Predictivo Adaptativo o A-MPC.

El objetivo principal de esta tesis, es proponer e implementar un sistema adaptativo para mejorar las prestaciones del controlador MPC de un inversor 3L-NPC, a partir del estudio detallado de su funcionamiento ante variaciones de diferentes parámetros .

Para realizar la adaptación ante dichas variaciones, el algoritmo que se propone en esta tesis, basará su funcionamiento en cambiar los factores de peso  $\lambda_{DC}$  y  $\lambda_{sw}$  de la función de coste, y para ello, utilizará un bloque previo al modelo predictivo, capaz de ajustar sus valores para que no se superen ciertas cotas impuestas a los índices de calidad. Por tanto, partiendo de la base del modelo del controlador MPC del apartado 2.3 mostrado en la Figura 19, en la Figura 46 se muestra lo propio para el algoritmo A-MPC.

Como se muestran en la Figura 46 resaltados en amarillo, se han incluido un nuevo bloque en el controlador, y nuevas referencias de entrada al sistema. El nuevo bloque es el encargado de modelar el comportamiento; y las nuevas entradas al sistema son los objetivos de control, añadidos a las referencias de potencia, cuantificados usando los índices de calidad definidos en el apartado 3.1.

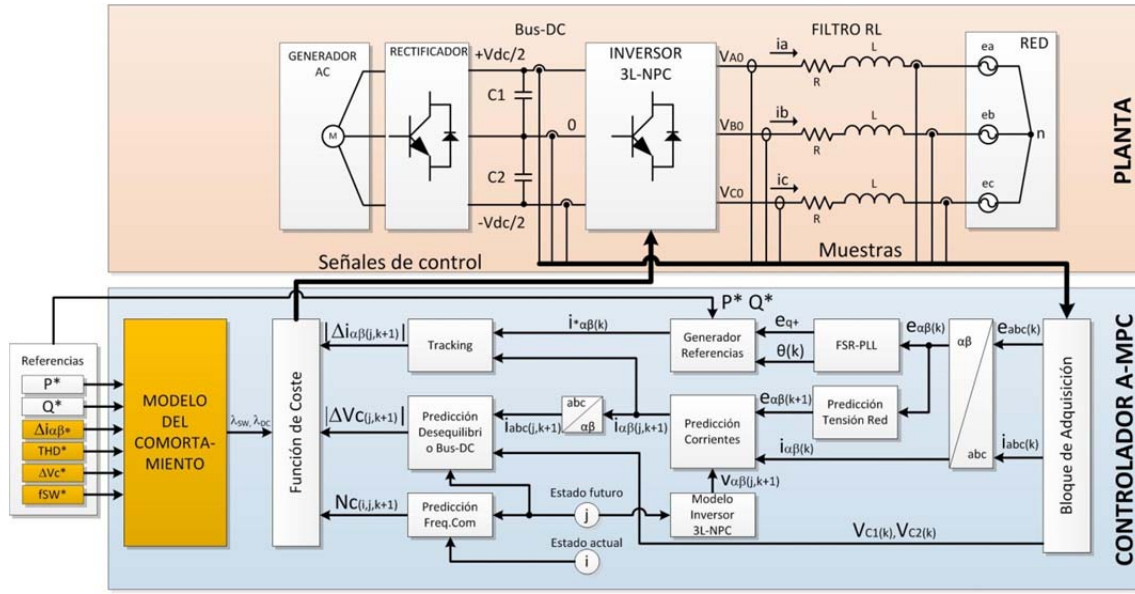


Figura 46. Diagrama de bloques del Algoritmo de Control Predictivo Adaptativo propuesto, basado en el MPC.

### 3.2.1 Modelo del comportamiento del controlador

Para poder predecir el comportamiento del inversor controlado, resulta indispensable estudiarlo previamente. En el capítulo anterior, se han expuesto resultados empíricos que relacionan diferentes magnitudes o elementos del sistema, con los índices de calidad aquí definidos. Sin embargo, en todos los experimentos, han permanecido fijos los factores de peso de la función de coste  $\lambda_{DC}$  y  $\lambda_{SW}$ . El objetivo era mostrar los efectos sobre el sistema de una única magnitud como si de una derivada parcial se tratase. Pero, como se puede intuir, si existiese una función global que expresase el comportamiento del sistema, esta sería multidimensional, con múltiples variables independientes de entrada, y múltiples variables de salida. Por otro lado, se ha visto que el sistema puede tener un comportamiento específico y único según las consignas de potencia  $P^*$  y  $Q^*$  que se apliquen. Ello hace que sea difícil o imposible encontrar una única función  $f$  que modele el comportamiento, sino que en realidad este se debe entender como un vector de funciones de estado que denominaremos  $F=(f_1, \dots, f_m)$  donde cada  $f_i$  modela el comportamiento para cierto par de valores de consigna  $(P^*, Q^*)$ .

Con lo visto en el punto 3.1, donde se definieron ciertos parámetros de calidad que son capaces de cuantificar el funcionamiento del inverso, se definirá el vector de estado del sistema  $\vec{Y}$  como el conjunto de dichos parámetros:  $(\Delta i_{\alpha\beta}, THD, \Delta V_c, f_{sw})$ .

Teniendo en cuenta las observaciones realizadas con anterioridad, se define la **función general del comportamiento** del algoritmo A-MPC  $F$ , como un vector de funciones de estado que permiten obtener el vector de estado del sistema  $\vec{Y}$  a partir de un conjunto o vector de valores de entrada al sistema  $\vec{X}$ , en el que al menos deberán estar las consignas de potencia  $S^*=(P^*,Q^*)$ , y los factores de peso de la función de coste  $\lambda_{DC}$  y  $\lambda_{SW}$ :

$$\begin{aligned}\vec{Y} &= (\Delta i_{\alpha\beta}, THD, \Delta Vc, f_{SW}) = F(\vec{X}) \\ &= \begin{cases} f_1(\lambda_{DC}, \lambda_{SW}, K_1, \dots, K_N) & \text{si } S = (P_1^*, Q_1^*) \\ \dots \\ f_m(\lambda_{DC}, \lambda_{SW}, K_1, \dots, K_N) & \text{si } S = (P_m^*, Q_m^*) \end{cases} \quad [52]\end{aligned}$$

definida para ‘ $m$ ’ diferentes consignas de potencia que abarquen todo el rango de configuración permitido del convertidor.

Los  $N$  parámetros  $K_i$ , representan todos aquellos elementos que influyen en el comportamiento del sistema, aunque a efectos del trabajo de esta tesis, se van a considerar constantes, prefijadas y no configurables, como por ejemplo: el período de muestreo  $T_s$ , la tensión del Bus-DC  $V_{DC}$  y sus condensadores, el filtro de red  $RL$  y la tensión nominal de red, entre otros. Sin embargo, el comportamiento de esta función depende también de la configuración de potencia deseada  $P^*$  y  $Q^*$ .

Viendo el diagrama de bloques del algoritmo A-MPC de la Figura 46, se llega a la conclusión de que lo que se busca es la función inversa a la definida en [52], mediante la cual se obtengan los factores de peso  $\lambda_{DC}$  y  $\lambda_{SW}$  a partir de un vector de estado de sistema deseado  $\vec{Y}^* = (\Delta i_{\alpha\beta}^*, THD^*, \Delta Vc^*, f_{SW}^*)$  para cierta consigna de potencia  $S^*=(P^*,Q^*)$ . Considerando ya  $K_1, \dots, K_N$  términos constantes en vez de variables, definiremos la función inversa de [52], como la **función de adaptabilidad** del algoritmo A-MPC:

$$\vec{X} = (\lambda_{DC}, \lambda_{SW}) = g(\vec{Y}^*) = \begin{cases} g_1(\Delta i_{\alpha\beta}^*, THD^*, \Delta Vc^*, f_{SW}^*) & \text{si } S = (P_1^*, Q_1^*) \\ \dots \\ g_m(\Delta i_{\alpha\beta}^*, THD^*, \Delta Vc^*, f_{SW}^*) & \text{si } S = (P_m^*, Q_m^*) \end{cases} \quad [53]$$

Esta función es la base del funcionamiento del algoritmo A-MPC, y ya fue presentada brevemente en la expresión [1] en el CAPÍTULO 1. La función de adaptabilidad sigue siendo un problema matemático multidimensional cuya aproximación no es trivial. En

este capítulo se discutirán las posibles opciones para aproximar esta función, sin embargo, sea cual sea el método, antes se debe obtener un espacio de observaciones suficientes, que permita conocer las relaciones de los índices de calidad, con los factores de peso, para cada configuración de potencia posible del inversor, de igual manera que para obtener la ecuación de una recta, se necesitan dos puntos.

### 3.3 Obtención del espacio de observaciones

Para obtener un espacio de observaciones que tenga la información necesaria para aproximar un modelo matemático para la función [ 52] y por tanto también la [ 53], se ha configurado el sistema en multitud de puntos de trabajo según las diferentes consignas de potencia que se le pueden exigir al convertidor, y en cada uno de ellos, a su vez se han obtenido los índices de calidad para cada combinación posible de  $\lambda_{DC}$  y  $\lambda_{SW}$ .

Para realizar los experimentos, de este punto, el inversor se ha ajustado con los siguientes parámetros:

Tensión Bus-DC	$V_{DC}=750 \text{ V}$
Tensión de red eléctrica (al neutro)	$e = 230 \text{ V rms}$
Período de muestreo	$T_s = 100\mu\text{s}$
Resistencia nominal del filtro	$R = 0.063 \Omega$
Inductancia nominal del filtro	$L = 1 \text{ mH}$
Max. Potencia del convertidor	100 kVA

#### 3.3.1 Márgenes de operación en potencia del inversor

Las consignas de potencia que puede seguir el inversor, estarán determinadas por la potencia máxima del mismo. La potencia máxima del convertidor utilizado para este trabajo es de 100kVA, por lo que mediante la expresión [ 21], este valor limita los puntos de trabajo del inversor a aquellos que cumplan la relación:

$$S = \sqrt{P^2 + Q^2} \leq 100kVA \quad [ 54]$$

Por otro lado, se sabe que la potencia activa  $P$  debe ser mayor o igual que cero, es decir, se asume un modo de funcionamiento del inversor en el que siempre deba entregar energía activa y no consumirla. La potencia reactiva  $Q$  puede tomar valores negativos, cuando se desea un comportamiento capacitivo, o positivos cuando se desea inductivo, los cuales tienen el efecto de provocar desfases entre las corrientes y las tensiones red. Por tanto, los límites de máximos de  $P$  y  $Q$ , siempre y cuando cumplan la relación [ 54], serán finalmente:

$$S = \sqrt{P^2 + Q^2} \leq 100kVA \quad P \geq 0 kW \quad -100kVAr \leq Q \leq +100kVAr \quad [ 55]$$

Cumpliendo [ 55], los márgenes de operación en potencia del inversor y el conjunto de consignas que se han analizado, se muestran en la Figura 47. Obviamente existen consignas de potencia distintas de las seleccionadas, pero el espacio de observaciones es suficiente, como se demostrará más adelante. Además, se debe asumir que la solución para aproximar el comportamiento de la función de adaptabilidad, debe tener cierta capacidad de interpolación para puntos no tenidos en cuenta, ya que de otro modo no sería una solución válida.




Figura 47. Diferentes puntos de trabajo considerados en cuanto a las consignas de potencia ( $P^*$ ,  $Q^*$ ).

Como se observa en la Figura 47, se han considerado puntos donde la potencia total suministrada por el convertidor sea de **25kVA, 50kVA, 75kVA y 100kVA**. Los valores concretos de todos estos puntos se muestran en la Tabla 11.

Tabla 11. Valores de los diferentes puntos de configuración de potencia (P\*,Q\*) considerados para obtener el espacio de observaciones.

Nº Combinación	P* [kW]	Q* [kVAr]	Nº Combinación	P* [kW]	Q* [kVAr]
1	0	100	27	0	50
2	25.8	96.6	28	12.9	48.3
3	50	86.6	29	25	43.3
4	70.7	70.7	30	35.4	35.4
5	86.6	50	31	43.3	25
6	96.6	25.8	32	48.3	12.9
7	100	0	33	50	0
8	96.6	-25.8	34	48.3	-12.9
9	86.6	-50	35	43.3	-25
10	70.7	-70.7	36	35.4	-35.4
11	50	-86.6	37	25	-43.3
12	25.8	-96.6	38	12.9	-48.3
13	0	-100	39	0	-50
14	0	75	40	0	25
15	19.4	72.4	41	6.47	24.15
16	37.5	64.9	42	12.5	21.65
17	53	53	43	17.68	17.68
18	64.9	37.5	44	21.65	12.5
19	72.5	19.4	45	24.15	6.47
20	75	0	46	25	0
21	72.5	-19.4	47	24.15	-6.47
22	64.9	-37.5	48	21.65	-12.5
23	53	-53	49	17.68	-17.68
24	37.5	-64.9	50	12.5	-21.65
25	19.4	-72.4	51	6.47	-24.15
26	0	-75	52	0	-25

### 3.3.2 Márgenes de variación de $\lambda_{DC}$ y $\lambda_{SW}$

El siguiente paso, es obtener el margen de variación de los factores de peso de la función de coste  $\lambda_{DC}$  y  $\lambda_{SW}$ . Para obtener los valores límites de los factores de peso de la función de coste, se consideran los siguientes límites de los índices de calidad, a



partir de los cuales las prestaciones del inversor no son adecuadas para aplicaciones reales:

- $0 \leq \Delta i_{\alpha\beta} \leq 25 \text{ Arms}$
- $0 \leq \text{THD} \leq 20\%$
- $0 \leq \Delta V_c \leq 12 \text{ V}$
- $0 \leq \text{Freq} \leq 2000 \text{ Hz}$

Estrictamente, como la función de modelado del comportamiento del sistema es en realidad un vector de funciones de estado para cada  $(P^*, Q^*)$ , cada una de ellas puede tener unos márgenes de variación de  $\lambda_{DC}$  y  $\lambda_{SW}$  específicos. No obstante, para no aumentar la complejidad matemática necesaria para encontrar una aproximación a la función  $g(\vec{Y}^*)$  definida en [ 53], se ha seguido un proceso empírico basado en múltiples experimentos a fin de obtener unos márgenes globales válidos para los factores de peso.

Se comenzó por un caso de estudio concreto, con una configuración de potencia activa de  $P^*=100\text{kW}$  y reactiva  $Q^*=0\text{kVAr}$ . En principio, el límite inferior para ambos pesos es cero. Esto se debe a que todos los términos de la función de coste son positivos y lo que se busca es minimizarla. Si se pusiesen pesos negativos, se podría dar el caso que un factor empeore muchísimo siendo muy positivo, y que otro con peso negativo lo compense falseando la propia función de coste. Por tanto, se realizaron pruebas empezando con ambos pesos en 0 y se aumentaron en pequeños pasos para ver la evolución de los índices de calidad. Además, como es un caso bidimensional, en el que dos variables intervienen ( $\lambda_{DC}$  y  $\lambda_{SW}$ ), para poder ver la variación relativa, se ha dejado un peso constante y se ha variado el otro.

A continuación se muestran los resultados cuando se prefijó  $\lambda_{SW}=0$  y se varió  $\lambda_{DC}$ .

Tabla 12. Dependencia con  $\lambda_{DC}$  de los índices de calidad para  $P^*=100\text{kW}$  y  $Q=0\text{kVAr}$ .

$\lambda_{DC}$	$\lambda_{SW}$	$\Delta i_{\alpha\beta} [\text{A}]$	THD [%]	$\Delta V_c [\text{V}]$	$f_{SW} [\text{Hz}]$
0	0	29.38	18.58	683	1497
0.5	0	18.45	11.9	10.2	1827
1	0	17.79	12.9	9.2	1787
1.5	0	17.93	11.75	6.24	1826
2	0	17.8	11.82	5.311	1718
2.5	0	16.93	11.39	5.26	1681
3	0	19.02	12.79	4.58	1765
3.5	0	19.11	12.62	4.05	1729
4	0	19.67	13.2	3.71	1828

$\lambda_{DC}$	$\lambda_{sw}$	$\Delta i_{\alpha\beta}$ [A]	THD [%]	$\Delta V_c$ [V]	$f_{sw}$ [Hz]
5	0	23.44	15.17	3.7	1868
6	0	23.7	15.68	3.55	1767
7	0	25.88	16.81	3.09	1863




Figura 48. Curvas de dependencia con  $\lambda_{DC}$  de los índices de calidad para  $P^*=100\text{kW}$  y  $Q=0\text{kVAr}$ .

Viendo los resultados anteriores, se pueden sacar las siguientes conclusiones. La variación, tanto de la desviación de corriente o *tracking*  $\Delta i_{\alpha\beta}$ , como de la distorsión armónica o THD, muestra que existe una zona de valores del peso  $\lambda_{DC}$  para los cuales se minimizan estas magnitudes. Como se observa, con  $\lambda_{DC}=0$  las corrientes se degradan bastante pues se desvían mucho de las referencias y la distorsión armónica es muy elevada. A partir de  $\lambda_{DC}=0.5$  y hasta  $\lambda_{DC}=4$  los cambios de este factor no tienen una influencia apreciable sobre estas dos magnitudes. Por último, a partir de  $\lambda_{DC}=4$  vuelven a aumentar los errores y distorsiones, aunque más lentamente.

Si se observa la evolución del desequilibrio del Bus-DC o  $\Delta V_c$ , se aprecia que la opción  $\lambda_{DC}=0$  queda descartada para el ajuste de la función de coste. Si no se realiza ningún control sobre esta magnitud, el desequilibrio en el bus-DC es elevado y acaba produciendo la degradación tanto en la desviación de corriente como en el THD. A partir de  $\lambda_{DC}=0.5$  el desequilibrio se va disminuyendo progresivamente según aumenta el control sobre  $\Delta V_c$ . En la Figura 49 se observa el detalle de la variación del desequilibrio cuando  $\lambda_{DC} \geq 0.5$ .




Figura 49. Detalle de variación del desequilibrio del Bus-DC para  $\lambda_{DC} \geq 0.5$ .

En cuanto a la frecuencia de conmutación de los IGBT, se observa claramente que para los valores de  $\lambda_{DC} \geq 0.5$ , se puede considerar independiente de este factor de peso.

Realizando el mismo proceso, escogiendo para  $\lambda_{DC}=2.5$  (valor de compromiso que asegura un buen comportamiento de los índices de calidad), se realizaron experimentos variando el peso  $\lambda_{SW}$ , obteniéndose los siguientes resultados:

Tabla 13. Dependencia con  $\lambda_{SW}$  de los índices de calidad para  $P^*=100\text{kW}$  y  $Q=0\text{kVAr}$ .

$\lambda_{DC}$	$\lambda_{SW}$	$\Delta i_{\alpha\beta}$ [A]	THD [%]	$\Delta V_c$ [V]	$f_{sw}$ [Hz]
2.5	0	16.93	11.39	5.26	1681
2.5	0.5	18.2	12.03	5.43	1783
2.5	1	17.8	12.2	5.19	1685
2.5	1.5	17.09	11.4	5.8	1643

$\lambda_{DC}$	$\lambda_{SW}$	$\Delta i_{\alpha\beta}$ [A]	THD [%]	$\Delta V_c$ [V]	$f_{sw}$ [Hz]
2.5	2	18.1	12.4	5.2	1738
2.5	3	18.5	12.2	5.7	1710
2.5	5	19.3	13.1	5.72	1625
2.5	7	18.3	12.4	6.3	1419
2.5	8	21.33	14.15	6.03	1480
2.5	9	20.02	13.4	6.9	1442
2.5	10	21.19	14.58	6.7	1369
2.5	11	20.18	13.81	8.07	1318
2.5	13	21.25	15.17	7.84	1292
2.5	15	20.8	14.5	8.27	1153
2.5	17	22.26	16.02	8.85	1066
2.5	19	22.5	15.49	10.01	1033




Figura 50. Curvas de dependencia con  $\lambda_{SW}$  de los índices de calidad para  $P^*=100\text{kW}$  y  $Q=0\text{kVAr}$ .

Observando la evolución de la desviación de corriente  $\Delta i_{\alpha\beta}$ , la distorsión armónica THD y el desequilibrio del bus-DC  $\Delta V_c$  con respecto al factor de peso  $\lambda_{SW}$ , se aprecia

que a medida que se aumenta este factor, se degradan los índices de calidad, excepto la frecuencia de conmutación, que por el contrario se reduce. En la Figura 50, se muestra la evolución un rango de variación del factor de peso que permite obtener resultados considerados útiles ya que si se fijan valores muy altos de  $\lambda_{SW}$  los parámetros de calidad se deterioran exponencialmente y no cumplirían los límites de los parámetros de calidad definidos anteriormente en este mismo punto. Como se observa, se puede concluir que  $0 \leq \lambda_{SW} \leq 20$  puede ser una variación aceptable para las condiciones de operación del inversor.

Hasta ahora, se han estudiado las variaciones de los índices de calidad con respecto a los pesos de la función de coste, es decir, la variación respecto a  $\lambda_{SW}$  suponiendo  $\lambda_{DC}$  constante, y viceversa. Como se sabe, la función de coste depende en realidad de los dos parámetros a la vez, con lo cual, para analizar la variabilidad conjunta, se realizaron experimentos modificando ambos parámetros a la vez, obteniéndose las gráficas de superficies y datos mostrados a continuación para el mismo caso de configuración de potencia ( $P^*=100\text{kW}$ ,  $Q^*=0\text{kVAr}$ ).

Tabla 14. Dependencia del desbalanceo de corriente  $\Delta i_{\alpha\beta}$  respecto a los parámetros de peso  $\lambda_{DC}$  y  $\lambda_{SW}$  de la función de coste.

$\Delta i_{\alpha\beta}$ [A]		$\lambda_{DC}$											
		0	0.5	1	1.5	2	2.5	3	3.5	4	5	6	7
$\lambda_{SW}$	0	29.38	17.44	17.79	17.93	17.8	16.93	19.02	19.11	19.67	23.44	23.7	25.88
	0.5	25.86	17.26	17.14	18.03	17.24	18.2	18.04	19.21	20.57	22.28	23.98	23.8
	1	26.75	16.34	16.39	16.99	17.76	17.8	18.5	19.76	19.1	21.57	24.76	27.12
	1.5	20.68	16.32	16.32	17.13	17.66	17.09	18.49	17.82	19.45	22.85	25.211	25.58
	2	26.64	17.16	16.16	18.7	17.77	18.1	17.43	18.21	19.43	21.31	24.02	25.51
	3	18.86	18.94	17.47	17.74	18.11	18.5	18.91	19.53	19.43	23.32	23.9	27.67
	5	24.83	18.11	18.11	18.89	18.82	19.3	20.33	19.74	21.49	21.62	23.3	26.18
	7	23.63	19.37	18.03	18.17	19.66	18.3	20.47	19.69	20.36	22.44	24.33	27.18
	8	22.92	19.77	19.46	19.24	19.46	21.33	18.81	20.98	21.33	22.7	25.74	27.23
	9	21.79	19.79	18.92	18.89	18.2	20.02	19.4	21.77	21.72	24.21	24.74	26.88
	10	27.1	20.44	19.22	18.92	18.3	21.19	19.72	19.86	21.21	25.15	25.33	27.54
	11	19.8	21.44	19.47	19.74	19.79	20.18	20.6	21.99	23.23	22.21	25.39	28.02
	13	24.9	20.33	21.38	20.1	19.81	21.25	22.33	23.19	23.17	25.05	25.94	27.97
	15	23.27	21.8	21.92	21.22	19.93	20.8	23.21	23.19	24.14	24.14	26.22	28.62
	17	23.63	21.92	22.13	23.22	21.63	22.26	22.61	25.43	24.83	26.83	30.57	30.12
	19	24.85	26.77	27.68	22.86	21.68	22.5	22.87	23.15	26.08	27.22	29.64	30.4

Si se observa la Figura 51, para la desviación de corriente  $\Delta i_{\alpha\beta}$ , y la Figura 52 para el THD, se llega a la conclusión de que ambos tienen diferentes zonas de

comportamiento, y que muestran tendencias similares. Como se observa en ambas gráficas, existen zonas en las que se minimizan (y por tanto se obtiene un mejor funcionamiento) los valores de estas funciones de calidad. Además, se demuestra que cerca de las zonas óptimas, ambas magnitudes se pueden considerar poco dependientes de los pesos, o dicho de otro modo, su valor se estabiliza en torno a un mínimo. Encontrar el punto de funcionamiento óptimo que minimice tanto la desviación en corriente como el THD, puede ser una tarea ardua, por lo que queda justificada la utilización de un sistema que sea capaz de modelar este comportamiento, máxime cuando se tiene en cuenta que las gráficas antes mostradas corresponden a una de las posibles referencias de potencia del sistema.




Figura 51. Gráfica de superficie de la desviación de corriente en función de  $\lambda_{DC}$  y  $\lambda_{SW}$ .

Tabla 15. Dependencia de la distorsión armónica o THD respecto a los parámetros de peso  $\lambda_{DC}$  y  $\lambda_{SW}$  de la función de coste.

THD [%]		$\lambda_{DC}$											
		0	0.5	1	1.5	2	2.5	3	3.5	4	5	6	7
$\lambda_{SW}$	0	18.58	11.9	12.9	11.75	11.82	11.39	12.79	12.62	13.2	15.17	15.66	16.81
	0.5	17.38	11.58	11.61	12.21	11.51	12.03	11.82	12.76	13.88	14.9	15.82	15.27
	1	17.76	11	11.26	11.79	11.85	12.2	12.5	13.14	12.82	14.31	16.3	17.91
	1.5	13.84	11.23	10.86	11.58	11.56	11.4	12.31	11.77	13.11	15.39	16.75	16.87
	2	17.95	11.43	10.64	12.45	11.98	12.4	12.01	12.14	13.16	14.13	16.01	16.96
	3	13.12	12.62	11.82	11.95	12.27	12.2	12.64	13.11	12.83	15.63	15.51	18.14
	5	16.51	12.32	12.34	13.14	12.56	13.1	13.84	13.24	14.67	14.32	15.32	17.14
	7	15.73	13.35	12.47	12.23	13.09	12.4	13.9	13.3	13.69	15.4	15.98	18.16
	8	15.01	13.13	13.1	12.97	13.18	14.15	13.12	14.21	14.29	15.19	17.25	18.31
	9	14.57	13.42	12.56	12.94	12.42	13.4	13.59	14.64	14.82	16.68	16.35	18.52
	10	18.38	14.14	13.04	12.92	12.53	14.58	13.52	13.88	14.37	16.79	16.77	18.39
	11	13.49	14.45	13.28	13.27	13.75	13.81	13.9	15.26	15.91	15.13	17.45	18.44
	13	17.07	14.23	14.42	13.65	13.8	15.17	15.43	15.91	15.69	17.43	17.87	18.9
	15	15.72	15.06	14.92	14.86	13.69	14.5	16.05	15.86	16.65	16.71	18.03	19.06
	17	16.32	15.14	15.24	15.65	14.63	16.02	16.36	17.55	17.67	18.62	21.06	20.92
	19	17.89	20.47	22.44	16.26	15.72	15.49	15.88	16.05	19.04	19.94	20.83	21.44




Figura 52. Gráfica de superficie del THD en función de  $\lambda_{DC}$  y  $\lambda_{SW}$ .

Tabla 16. Dependencia del desequilibrio del bus-DC respecto a los parámetros de peso  $\lambda_{DC}$  y  $\lambda_{SW}$  de la función de coste.

$\Delta V_c$ [V]		$\lambda_{DC}$											
		0	0.5	1	1.5	2	2.5	3	3.5	4	5	6	7
$\lambda_{SW}$	0	683	10.2	9.2	6.24	5.311	5.26	4.58	4.05	3.71	3.7	3.55	3.09
	0.5	476	9.81	8.85	8.9	5.47	5.43	4.83	4.47	3.68	3.6	3.1	3.44
	1	548	11.6	8.65	6.24	5.43	5.19	4.3824	3.8459	4.55	3.2	3.68	2.76
	1.5	240	10.07	8.04	6.84	6.45	5.8	4.74	4.69	4.28	3.48	3.38	3.69
	2	516	10.87	10.09	7.36	6.45	5.2	5.22	4.89	4.83	4.25	3.94	3.66
	3	116	12.87	9.34	7.29	6.13	5.7	4.66	4.62	5.02	4.16	3.69	3.08
	5	346	16.65	12.53	8.7	6.73	5.72	5.22	5.0464	4.78	4.49	4.48	3.43
	7	360	19.28	12.9	8.63	6.89	6.3	5.03	5.16	5.06	4.95	3.94	3.68
	8	318	20.333	12.55	9.42	7.51	6.03	5.87	5.36	5.26	4.37	4.4	3.76
	9	237	30.143	14.17	11.1	8.7	6.9	6.77	5.34	5.37	4.69	4.3	3.28
	10	447	88.41	12.95	10.2	8.52	6.7	6.76	5.75	5.7	4.58	4.66	3.8
	11	66	136.74	13.15	12.7	8.21	8.07	6.51	6.03	5.17	5.05	3.56	3.62
	13	382	76.85	15.43	10.95	9.47	7.84	6.44	6.61	5.58	4.45	4.31	4.21
	15	233	73.82	16.61	12.24	12.04	8.27	6.34	6.45	5.83	5.48	4.77	3.92
	17	151	153	19.77	14.16	10.28	8.85	7.47	6.08	6.77	5.31	4.45	4.2
	19	203	83.93	27.94	15.92	11.96	10.01	8.18	6.8	6.56	5.63	4.71	2.98




Figura 53. Gráfica de superficie (recortada) del desequilibrio del bus-DC en función de  $\lambda_{DC}$  y  $\lambda_{SW}$ .



Tabla 17. Dependencia de la frecuencia de conmutación de los IGBT respecto a los parámetros de peso  $\lambda_{DC}$  y  $\lambda_{SW}$  de la función de coste.

Freq [Hz]		$\lambda_{DC}$											
		0	0.5	1	1.5	2	2.5	3	3.5	4	5	6	7
$\lambda_{SW}$	0	1497	1827	1787	1826	1718	1681	1765	1729	1828	1868	1767	1863
	0.5	1518	1817	1777	1752	1749	1783	1772	1801	1755	1750	1742	1750
	1	1499	1636	1660	1754	1742	1685	1705	1779	1688	1725	1788	1779
	1.5	1387	1681	1657	1666	1663	1643	1729	1685	1693	1750	1781	1743
	2	1391	1557	1683	1786	1680	1738	1661	1652	1698	1712	1716	1706
	3	1291	1633	1614	1664	1634	1710	1666	1698	1631	1708	1722	1680
	5	1404	1444	1541	1583	1626	1625	1590	1555	1627	1599	1556	1608
	7	1286	1450	1361	1435	1451	1419	1592	1484	1533	1531	1527	1499
	8	1310	1401	1404	1394	1463	1480	1452	1463	1496	1470	1478	1473
	9	1250	1425	1308	1395	1293	1442	1358	1473	1374	1479	1478	1474
	10	1337	1313	1283	1250	1254	1369	1299	1421	1427	1426	1384	1482
	11	1195	1232	1279	1308	1263	1318	1318	1403	1340	1409	1405	1449
	13	1159	1122	1273	1212	1123	1292	1292	1287	1375	1315	1364	1395
	15	1083	1194	1182	1123	1048	1153	1261	1303	1219	1335	1293	1305
	17	951	1010	1069	1089	1100	1066	1143	1215	1156	1260	1257	1243
	19	893	891	1028	1032	938	1033	1038	1066	1096	1206	1138	1201




Figura 54. Gráfica de superficie de la frecuencia de conmutación en función de  $\lambda_{DC}$  y  $\lambda_{SW}$ .

Las otras dos magnitudes, varían de forma diferente con respecto a los pesos. La Figura 53 muestra cómo existe una dependencia directa entre el peso  $\lambda_{DC}$  y el desequilibrio que se produce en el bus-DC. La gráfica aparece recortada, ya que si se consulta la Tabla 16, se observa que los valores que se obtienen cuando  $\lambda_{DC}=0$  son muy elevados respecto a los mostrados. Se observa como en general, para cualquier valor de  $\lambda_{SW}$ , el desequilibrio se va reduciendo a medida que va aumentando  $\lambda_{DC}$ . Sin embargo, también se observa una pequeña dependencia con respecto a  $\lambda_{SW}$ , cuando este toma valores muy altos y  $\lambda_{DC}$  valores muy bajos, ya que esta condición equivaldría a que el control del desequilibrio del Bus-DC está poco amortiguado, dándose mayor importancia a la frecuencia de conmutación.

En cuanto a la frecuencia de conmutación de los IGBT, se observa en la Figura 54 como tiene una dependencia directa con respecto a la  $\lambda_{SW}$ , y en cambio se puede considerar independiente respecto al peso  $\lambda_{DC}$ , lo cual se muestra claramente en la gráfica de superficie, si vemos que las bandas de colores de los rangos de valores son paralelas al eje  $\lambda_{DC}$ .

A partir de los resultados obtenidos para un caso concreto de potencia, el último paso consiste en realizar un estudio de los índices de calidad, para algunos otros casos de configuración de potencia que sean representativos, aunque no estén incluidos en la constelación de la Figura 47.

Para corroborar la dependencia respecto de las consignas de potencia, se muestra a continuación un estudio que incluye el caso anteriormente analizado y otros dos casos diferentes:

- CASO 1:  $P=100\text{kW}$ ,  $Q=0\text{kVAr}$ , en el que toda la potencia es activa.
- CASO 2:  $P=60\text{kW}$ ,  $Q=80\text{kVAr}$ , en el que se introducirá un valor de potencia reactiva  $Q$ , conservando también gran parte de la potencia activa  $P$ .
- CASO 3:  $P=43\text{kW}$ ,  $Q=90\text{kVAr}$ , donde predomina la potencia reactiva sobre la activa.

En las siguientes tablas e imágenes se muestran los tres casos diferentes de configuración de potencia, en dependencia del peso  $\lambda_{DC}$ , considerando que no se realiza ningún control sobre la frecuencia de conmutación, es decir con  $\lambda_{SW} = 0$ .

Tabla 18. Dependencia con  $\lambda_{DC}$  de los índices de calidad para  $P^*=60\text{kW}$  y  $Q=80\text{kVAr}$ .

CASO 2: $P=60\text{kW}$ $Q=80\text{kVAr}$					
$\lambda_{DC}$	$\lambda_{SW}$	$\Delta i\alpha\beta$ [A]	THD [%]	$\Delta V_c$ [V]	$f_{sw}$ [Hz]
0	0	25.95	15.48	392.76	1197

CASO 2: P=60kW Q=80kVAr					
$\lambda_{DC}$	$\lambda_{SW}$	$\Delta i_{\alpha\beta}$ [A]	THD [%]	$\Delta V_c$ [V]	$f_{SW}$ [Hz]
0.5	0	17.14	10.9	19.2	1433
1	0	19.32	11.93	10.69	1591
1.5	0	19.67	11.98	7.67	1648
2	0	19.5282	12.19	5.8	1609
2.5	0	20.77	12.72	4.82	1586
3	0	21.26	13.1	3.847	1597
3.5	0	20.6	12.67	3.78	1551
4	0	22.48	13.56	3.66	1541
5	0	24.49	14.85	3.19	1594
6	0	28.8	17.27	2.95	1535
7	0	29.12	17.92	2.87	1612

Tabla 19. Dependencia con  $\lambda_{DC}$  de los índices de calidad para P\*=43kW y Q=90kVAr.

CASO 3: P=43kW Q=90kVAr					
$\lambda_{DC}$	$\lambda_{SW}$	$\Delta i_{\alpha\beta}$ [A]	THD [%]	$\Delta V_c$ [V]	$f_{SW}$ [Hz]
0	0	22.93	13.64	315.37	1186
0.5	0	18.7	11.76	21.3	1504
1	0	18.28	11.18	13.4	1545
1.5	0	19.649	11.91	7.9551	1533
2	0	19.37	11.81	5.83	1474
2.5	0	21.5	13.01	4.86	1503
3	0	21.77	13.17	4.42	1508
3.5	0	22.92	13.7	3.64	1511
4	0	22.11	13.33	3.57	1531
5	0	26.46	15.46	3.55	1580
6	0	27.69	17.74	2.47	1561
7	0	31.48	21.05	2.24	1501

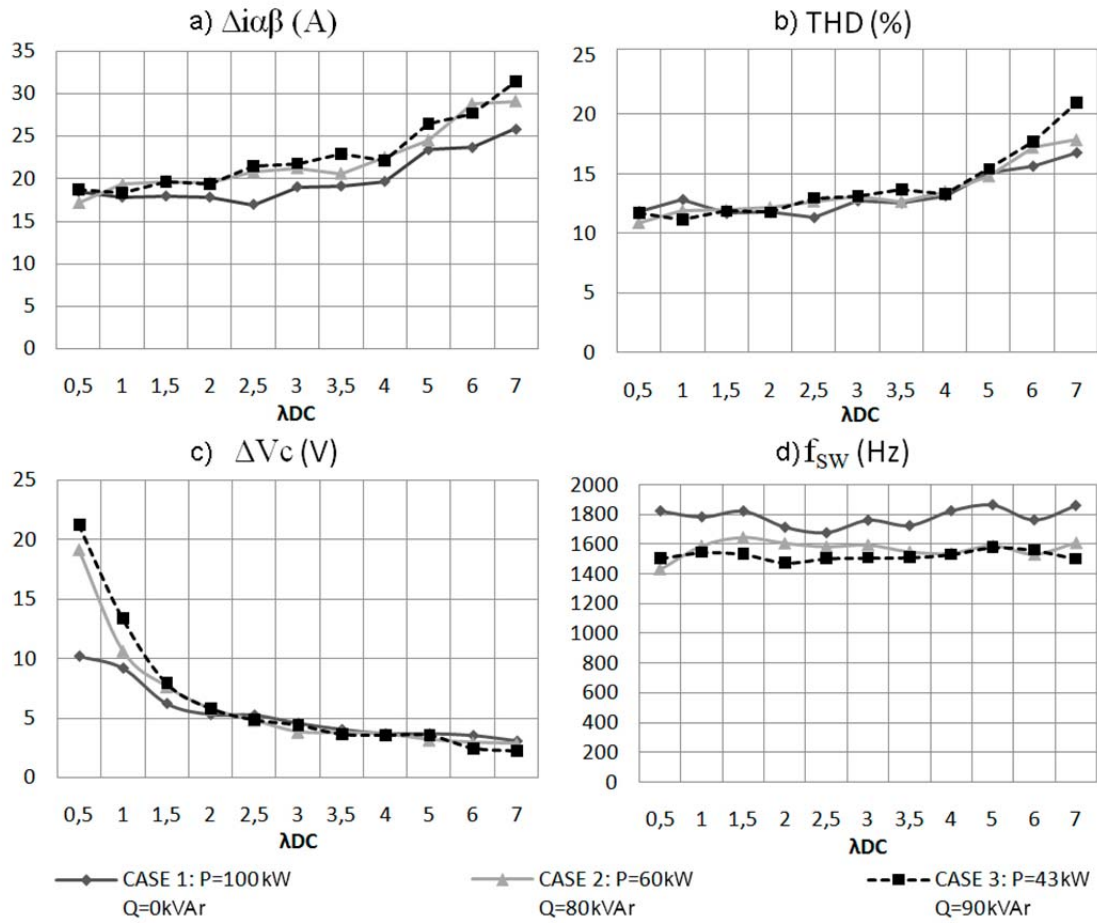


Figura 55. Comparativa de curvas de dependencia con  $\lambda_{DC}$  de los índices de calidad para los tres casos de configuración de potencia prefijados.

A la vista de la Figura 55 (a) y (b), podemos sacar diferentes conclusiones según qué índice de calidad observemos. Tanto la desviación en corriente  $\Delta ia\beta$  o *tracking*, como el THD del sistema, resultan dependientes de la configuración de potencia, más el THD que el *tracking*. En términos generales, se llega a la conclusión de que al introducir potencia reactiva, se degradan las corrientes generadas, y el factor de peso  $\lambda_{DC}$  óptimo en cada caso, dependerá de la configuración de potencia.

En cuanto al desequilibrio que se produce en el bus-DC mostrado en la Figura 55 (c), se observa cómo a medida que la potencia reactiva  $Q$  aumenta, a costa de reducir la potencia activa  $P$ , para valores de  $\lambda_{DC} < 2$  será mayor el desequilibrio cuanto mayor sea la potencia reactiva. Para valores de  $\lambda_{DC} > 2$  el desequilibrio y su control evolucionan prácticamente independiente de la configuración de potencia. No obstante, esto no implica la elección de un  $\lambda_{DC}$  fijo como solución, ya que no solo se debe ver el desequilibrio en el Bus-DC. Por ejemplo, un valor que haga óptimo el desequilibrio del

bus-DC, puede que haga inaceptable el  $THD$  o el  $\Delta i\alpha\beta$ . Cabe recordar también que para estas gráficas, se ha considerado el caso en el que  $\lambda_{SW}=0$ , pero existirán variaciones de los índices de calidad cuando se cambie este valor como ya se ha demostrado anteriormente en los curvas de dependencias para el CASO 1.

La gráfica parametrizada de la respuesta de la frecuencia de conmutación mostrada en la Figura 55 (d), muestra cómo la frecuencia de conmutación se puede considerar independiente del peso  $\lambda_{DC}$ , no obstante, el orden de magnitud de la misma depende directamente de la referencia de potencia reactiva, observándose que cuanto más alta sea la potencia activa respecto a la reactiva, mayor será la frecuencia de conmutación.

Se puede realizar un estudio idéntico al anterior, considerando ahora fijo el peso  $\lambda_{DC} = 0.5$  (ya que cómo ha quedado demostrado el valor  $\lambda_{DC} = 0$  hace que el desequilibrio del Bus-DC sea inviable), y obteniendo las dependencias con respecto a  $\lambda_{SW}$  en los tres diferentes escenarios de potencia. Al igual que con la variación respecto a  $\lambda_{DC}$ , no se muestran los resultados para el CASO 1 ya estudiado.

Tabla 20. Dependencia con  $\lambda_{SW}$  de los índices de calidad para  $P^*=60\text{kW}$  y  $Q=80\text{kVAr}$ .

CASE 2: P=60kW Q=80kVAr					
$\lambda_{DC}$	$\lambda_{SW}$	$\Delta i\alpha\beta$ [A]	THD [%]	$\Delta V_c$ [V]	$f_{SW}$ [Hz]
0.5	0	17.14	10.9	19.2	1433
0.5	0.5	17.09	10.85	17.25	1445
0.5	1	17.08	10.89	18.5	1411
0.5	1.5	18.57	11.96	17.21	1406
0.5	2	17.65	11.41	19.16	1379
0.5	3	18.02	11.5	19.35	1322
0.5	5	19.2	12.43	20.63	1265
0.5	7	18.72	12.43	30.08	1128
0.5	8	19.47	12.72	36.61	1159
0.5	9	18.16	12.11	33.02	1013
0.5	10	20.3	13.12	27.8	1054
0.5	11	18.48	12.25	35.92	921
0.5	13	20.37	13.33	27.93	1010
0.5	15	19.16	12.94	35.4	809
0.5	17	19.98	13.45	39.18	892
0.5	19	22.8	15.87	32.52	880

Tabla 21. Dependencia con  $\lambda_{SW}$  de los índices de calidad para  $P^*=43\text{kW}$  y  $Q=90\text{kVAr}$ .

CASE 3: P=43kW Q=90kVAr					
$\lambda_{DC}$	$\lambda_{SW}$	$\Delta i\alpha\beta$ [A]	THD [%]	$\Delta V_c$ [V]	$f_{SW}$ [Hz]

CASE 3: P=43kW Q=90kVAr					
$\lambda_{DC}$	$\lambda_{SW}$	$\Delta i_{\alpha\beta}$ [A]	THD [%]	$\Delta V_c$ [V]	$f_{SW}$ [Hz]
0.5	0	18.7	11.76	16.98	1504
0.5	0.5	17.5	10.88	21.55	1406
0.5	1	17.02	10.91	21.81	1376
0.5	1.5	17.57	11.09	24.6	1253
0.5	2	18.6	11.9	23.35	1311
0.5	3	17.63	11.54	22.63	1293
0.5	5	17.79	11.35	29.72	1162
0.5	7	18.16	11.82	26.32	1104
0.5	8	18.61	11.97	31.85	1007
0.5	9	18.52	11.97	41.31	989
0.5	10	17.17	11.53	39.58	875
0.5	11	19.5	12.57	34.45	1032
0.5	13	20.4	13.4	46.45	924
0.5	15	18.4	12.44	37.35	742
0.5	17	21.25	13.39	46.31	677
0.5	19	20.29	13.72	48.15	682

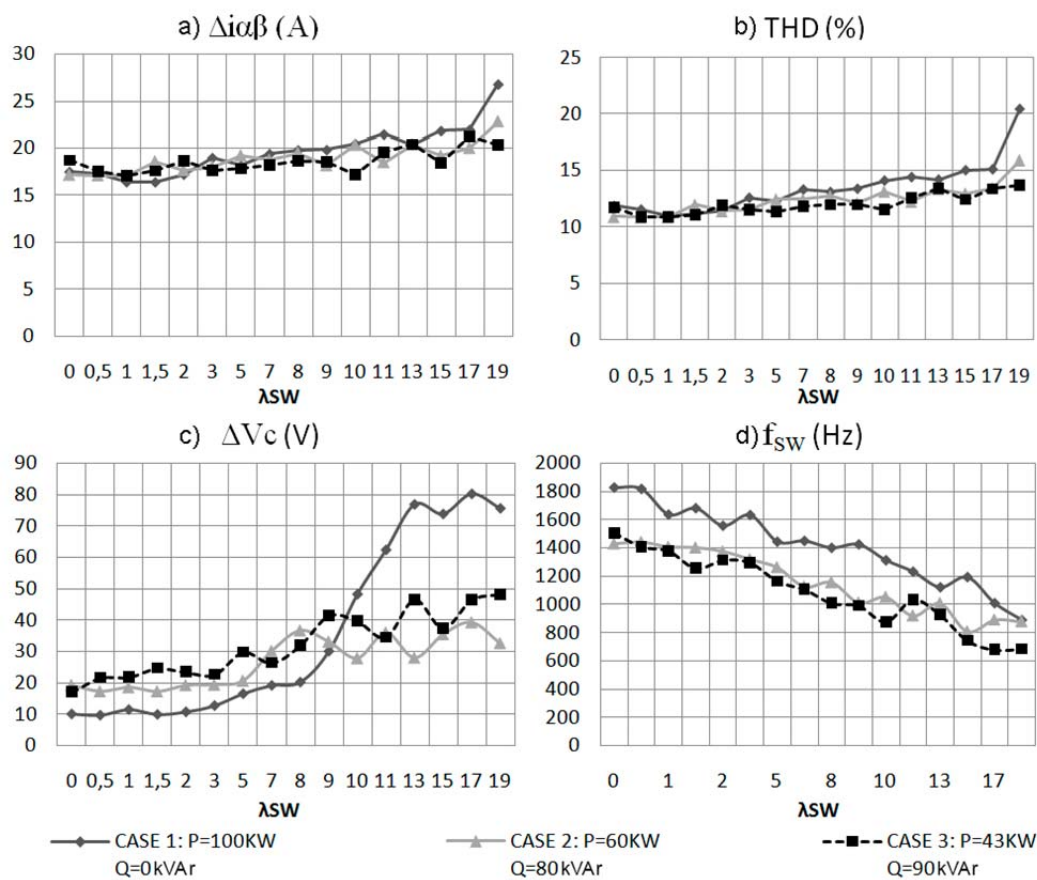


Figura 56. Comparativa de curvas de dependencia con  $\lambda_{SW}$  de los índices de calidad para los tres casos de configuración de potencia prefijados.

Viendo la Figura 56 (a) y (b), se observa que tanto la desviación de corriente  $\Delta i\alpha\beta$ , como el  $THD$ , son parámetros que no dependen mucho de  $\lambda_{SW}$  según las referencias de potencia que apliquen. Solo cuando el peso  $\lambda_{SW}$  aumenta mucho de valor, haciendo que el *tracking* pierda importancia con respecto al control de la frecuencia de conmutación de los IGBT, estas magnitudes empiezan a deteriorarse rápidamente.

El desequilibrio del Bus-DC mostrado en la Figura 56 (c) aumenta según va teniendo más peso el control de la frecuencia de conmutación (con  $\lambda_{SW}$  mayores), hasta que se alcanza el valor de  $\lambda_{SW} = 9$ , y además es más alto cuanto más potencia reactiva se tenga. A partir de este punto, cuando el sistema solo tiene potencia activa  $P$ , el desequilibrio del Bus-DC se hace patente debido a que el control del bus-DC pierde importancia con respecto al control sobre la conmutación de los IGBT. A medida que se añade más potencia reactiva, el comportamiento es semejante, pero ocurre para valores de  $\lambda_{SW}$  superiores.

En la Figura 56 (d) se muestra que la frecuencia de conmutación del convertidor tiene gran dependencia de las consignas de potencia. Al igual que pasaba cuando se caracterizó esta magnitud con respecto a  $\lambda_{DC}$  para varios escenarios (Figura 55), a medida que el sistema tiene más potencia reactiva  $Q$ , la frecuencia de conmutación se reduce, de manera altamente dependiente de  $\lambda_{SW}$ .

Como conclusión a este apartado, se ha podido ver cómo el comportamiento del sistema, y en concreto los índices de calidad que se han tenido en cuenta en este estudio,  $\Delta i\alpha\beta$ ,  $THD$ ,  $\Delta Vc$  y  $f_{SW}$ , dependen fuertemente de los pesos  $\lambda_{DC}$  y  $\lambda_{SW}$ , y de las consignas de potencia  $P^*$  y  $Q^*$ . Además, las dependencias son altamente no lineales. No obstante, según los resultados expuestos, se pueden obtener ciertos márgenes de variación para los pesos de la función de coste, fuera de los cuales el comportamiento del inversor no es aceptable para aplicaciones reales. Los márgenes o rangos de valores para los pesos que se van a considerar viables en función de los resultados, son:

$$0.5 \leq \lambda_{DC} \leq 10$$

$$0 \leq \lambda_{SW} \leq 20$$

[ 56]

### 3.3.3 Obtención de índices de calidad

Una vez definidos todos los puntos posibles de configuración de potencia, y los valores admisibles para los factores de peso  $\lambda_{DC}$  y  $\lambda_{SW}$ , se ha hecho funcionar el algoritmo de control MPC (no adaptativo), configurándolo con cada una de las consignas de potencia de la Tabla 11; y en cada una de ellas, se han hecho variar los factores de pesos de forma escalonada con 10 valores posibles dentro de sus rangos, tal como se representa en la Figura 57 para el caso en el que la potencia del convertidor es de 100kW. Para el resto de configuraciones de potencia del convertidor, se han tenido los mismos patrones.

Con estas variaciones, en total se tienen 52 referencias de potencia, y en cada uno 10 valores diferentes de  $\lambda_{DC}$  y a su vez 10 de  $\lambda_{SW}$ , haciendo en total 5200 combinaciones diferentes.




Figura 57. Variación de los parámetros de configuración del algoritmo MPC para obtener el espacio de observaciones.

Para cada caso o vector de configuración del sistema  $\vec{X}$ , se han calculado los índices de calidad antes definidos. Se debe recordar que el propio algoritmo MPC tiene un tiempo de respuesta o transitorio de unos 7 ms después de un cambio de consignas, y este análisis se debe hacer para un régimen permanente, por lo que cada situación se debe simular para que el tiempo de régimen permanente sea mucho mayor que el transitorio (más de 70 ms). Concretamente, para cada combinación posible, se han calculado los índices de calidad durante **5 ciclos** de señal de 50 Hz (100ms). Por tanto



para obtener todos los datos deseados, se han tomado muestras durante  $5\text{ciclos} \times 20\text{ms/ciclo} \times 5200\text{combinaciones} = \mathbf{520 \text{ segundos}}$  de funcionamiento (más de 8 minutos). Y durante este tiempo, a una frecuencia de muestreo de  $T_s=100\mu\text{s}$ , se han obtenido unas **26.000.000 muestras**, correspondientes a  $(3 \text{ corrientes} + 2 \text{ tensiones del Bus-DC}) \times 5.200.000 \text{ muestras por señal}$ . Hay que recordar que con las tres corrientes se calcula la desviación  $\Delta i\alpha\beta$  y el  $THD$ , con las tensiones del Bus-DC el desequilibrio  $\Delta V_c$ , mientras que  $f_{sw}$  se calcula sin necesidad de muestrear ninguna señal conociendo la señal de actuación del controlador.

Con todos estos casos de funcionamiento, se ha construido una extensa base de datos con registros correspondientes al espacio de observaciones, que relaciona las variables de entrada o consignas del sistema,  $P^*$ ,  $Q^*$ ,  $\lambda_{DC}$  y  $\lambda_{sw}$ , con las variables de salida  $\Delta i\alpha\beta$ ,  $THD$ ,  $\Delta V_c$  y  $f_{sw}$ . Es decir, se tiene el espacio de observaciones que se necesita para aproximar o describir la función que describe el comportamiento del sistema expuesta en [ 52]. Sin embargo, como ya se ha demostrado, dicha función no parece factible de ajustes mediante un modelo matemático único, ni de forma sencilla.

Con esta base de datos, el objetivo de este trabajo es encontrar un método fiable que sea capaz de modelar el sistema en sentido inverso, es decir, que para una referencia de potencia determinada, y a partir de unos índices de calidad, se obtengan los parámetros  $\lambda_{DC}$  y  $\lambda_{sw}$  que se necesitan para la función de coste. Este método de actuación se describe gráficamente en la Figura 58, donde se indica que será la base de datos del espacio de observaciones, el punto de partida para desarrollar el modelo que se ya se definió en [ 53].

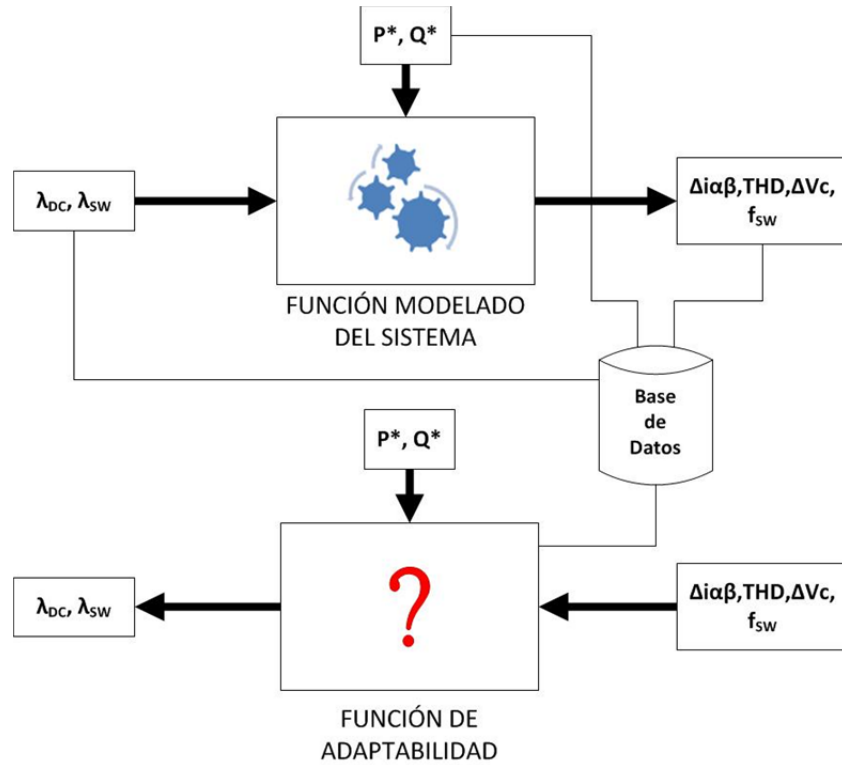


Figura 58. Esquema de actuación para encontrar el modelo de adaptabilidad del algoritmo de Control Predictivo.

Los registros de la base de datos se dividen en dos conjuntos:

- **Patrones de entrenamiento**, que se usarán como vectores de entrada  $\vec{X}_{TRAIN}$  para las técnicas de modelado y optimización que se propondrán posteriormente. Cada registro de entrenamiento está compuesto por un vector de entrada  $[P, Q, \Delta i\alpha\beta, THD, \Delta Vc, f_{SW}]$ , y el correspondiente vector de salida  $\vec{Y}_{TRAIN} = [\lambda_{DC}, \lambda_{SW}]$ . Este bloque supone el **70%** del conjunto total de observaciones dentro de la base de datos.
- **Patrones de validación** para realizar la comprobación de la solución propuesta, compuesta por vectores de entrada  $\vec{X}_{TEST}$  y sus asociados de salida  $\vec{Y}_{TEST}$ . El objetivo es separar un conjunto de datos que no se hayan usado para entrenamiento, y así validar la respuesta del modelo ante entradas desconocidas. Este conjunto supone en torno al **30%** de la base de datos.

En el siguiente apartado, se mostrarán y analizarán algunas posibles soluciones para aproximar el modelo del algoritmo A-MPC.

### 3.4 Posibles soluciones para diseñar la función de adaptabilidad

Llegados a este punto, se ha cuantificado la relación entre los diferentes parámetros del controlador, del inversor y los índices de calidad, lo que ha dado lugar a una extensa base de datos sobre la que poder aplicar diferentes técnicas de modelado y optimización. Se hace pues necesario, encontrar la mejor solución que permita aproximar el algoritmo A-MPC. Recordando la expresión [1] vista en el capítulo introductorio, se resume el objetivo en encontrar una función como la que sigue:

$$(\lambda_{SW}, \lambda_{DC}) = g(P^*, Q^*, \Delta i \alpha \beta^*, THD^*, \Delta V_{DC}^*, f_{SW}^*) \quad [57]$$

donde como se observa, los índices de calidad son considerados como objetivos de control (entradas por tanto) del algoritmo A-MPC, indicándolo con un ‘\*’.

Todo el estudio realizado con anterioridad, resulta indispensable para saber qué método se puede aplicar y cual no es tan conveniente. A continuación, se describirán diferentes alternativas para aproximar funciones o comportamientos como los presentes, indicando en cada su aplicabilidad al caso concreto descrito en esta tesis.

Un requisito importante a la hora de optar por una solución, es que sea factible su implementación. Por ejemplo, cuando se usan FPGAs, se debe traducir el algoritmo preferentemente a operaciones MAC (Multiply-ACcumulate operations). En cambio, usando un DSP, no existe esta restricción, dado que el algoritmo se traduce usando un lenguaje de programación normalmente más versátil. No obstante se deben evaluar los posibles inconvenientes, algunos ya comentados, como el instante de aplicación de la actuación. Ante dos soluciones válidas, se seleccionará la menos costosa a la hora de la implementación.

#### 3.4.1 Regresión lineal múltiple

La regresión lineal múltiple, es una técnica para raproxima funciones utilizado cuando las variables de salida, respuestas o variables dependientes representadas por los pesos  $\lambda_{DC}$  y  $\lambda_{SW}$ , puedan expresarse como combinación lineal de las variables de entrada, llamadas explicativas (49) (50), formadas en este caso por las consignas de potencia y los índices de calidad como objetivos de control. La expresión [56] puede considerarse como dos funciones individuales para cada una de las salidas:

$$\lambda_{DC} = \omega_0 + \omega_1 \cdot P^* + \omega_2 \cdot Q^* + \omega_3 \cdot \Delta i \alpha \beta^* + \omega_4 \cdot THD^* + \omega_5 \cdot \Delta V_C^* + \omega_6 \cdot f_{SW}^* + \varepsilon$$

$$\lambda_{SW} = \gamma_0 + \gamma_1 \cdot P^* + \gamma_2 \cdot Q^* + \gamma_3 \cdot \Delta i \alpha \beta^* + \gamma_4 \cdot THD^* + \gamma_5 \cdot \Delta V_{DC}^* + \gamma_6 \cdot f_{SW}^* + \delta$$

[ 58]

donde  $\omega_0$  y  $\gamma_0$  son términos constantes, los  $\omega_i$  y  $\gamma_i$  son los coeficientes de regresión, y  $\varepsilon$  y  $\delta$  son términos que definen una posible perturbación o error aleatorio, normalmente de media nula. En un caso de regresión lineal unidimensional, existe una variable independiente  $X$ , y una de salida  $Y$ , y la aproximación de la función que relaciona ambas será una recta. Este es el caso de la aproximación por mínimos cuadrados comúnmente usada como el visto en la Figura 59 (a). Si se traslada el problema a dos variables de entrada  $X$ ,  $Y$ , y una variable de salida  $Z$ , la solución pasa por encontrar la ecuación de un plano que describa lo mejor posible la relación entre las entradas y la salida, como en la Figura 59 (b). Para el caso de múltiples variables de entrada como en [ 58], la aproximación se realiza según un *hiperplano*.

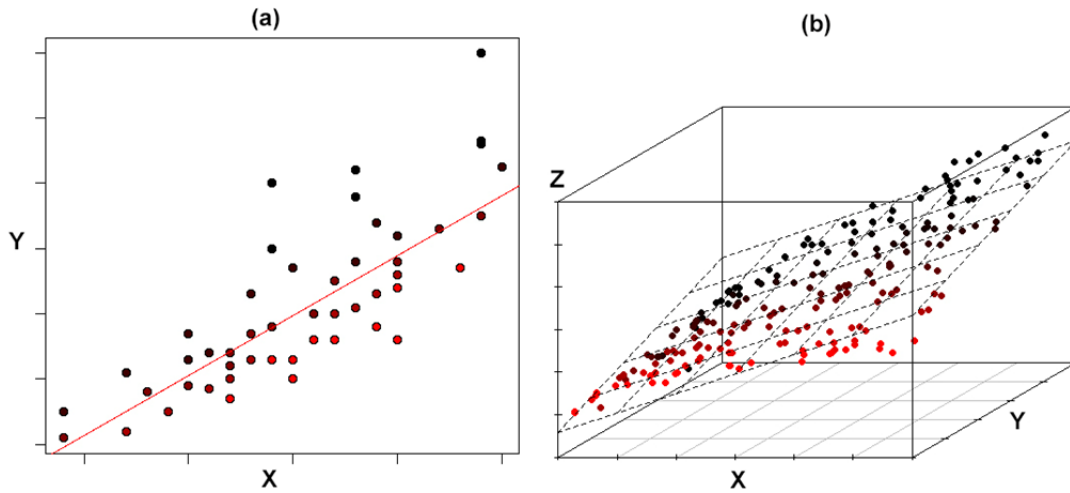


Figura 59. Ejemplos de regresión lineal unidimensional (a) y bidimensional (b). Mathworks ®

No obstante estos modelos se usan para modelar comportamientos donde las salidas tengan una dependencia lineal respecto a las entradas. Este comportamiento no se ajusta con el caso de estudio de esta tesis, según lo visto en el apartado 3.3.2. Su aplicación a la colección de observaciones de la base de datos  $\vec{X}_{TRAIN}$  y sus respectivos  $\vec{Y}_{TRAIN}$ , se ha llevado a cabo usando las herramientas de MATLAB para obtener los coeficientes de regresión en un caso de múltiples variables (64).

Con la función de MATLAB **regress()**, se han obtenido los siguientes coeficientes de regresión para aproximar mediante hiperplanos la relación entre los pesos y las variables de referencia del sistema:

Tabla 22. Coeficientes de regresión lineal encontrados para modelar el comportamiento del sistema.

		P	Q	$\Delta\alpha\beta$	THD	$\Delta V_c$	$f_{sw}$
$\lambda_{DC}$	$\omega_0$	$\omega_1$	$\omega_2$	$\omega_3$	$\omega_4$	$\omega_5$	$\omega_6$
	-6.9068	1.7e-5	2.8e-7	0.2248	4.9711	-0.0679	0.0036
$\lambda_{SW}$	$\gamma_0$	$\gamma_1$	$\gamma_2$	$\gamma_3$	$\gamma_4$	$\gamma_5$	$\gamma_6$
	34.2863	1.29e-5	-6.8e-5	0.1777	1.5379	-0.0388	-0.0207

El significado matemático que los coeficientes de regresión representan, es el grado de dependencia lineal de cada término respecto a la salida. Como se puede apreciar en los resultados anteriores, los coeficientes para P y Q son muy bajos respecto a los demás términos (tienden a cero). Ello significaría que no se ha encontrado una dependencia lineal, por lo que su influencia es prácticamente nula en la función de aproximación lineal. Como ya se ha estudiado, esto está claramente justificado, por el hecho de que el comportamiento del sistema depende fuertemente de las consignas de potencia  $P^*$ ,  $Q^*$ , siendo además una dependencia no lineal.

Usando los coeficientes de la Tabla 22 en las expresiones [ 58] sobre el conjunto de observaciones de la base de datos  $\vec{X}_{TEST}$  y  $\vec{Y}_{TEST}$  para validar la aproximación, se ha obtenido una respuesta como la mostrada en la Figura 60, donde se representan los patrones de validación, o de test  $\lambda_{DC\_TEST}$  y  $\lambda_{SW\_TEST}$  los resultados reales tras aplicar el modelo. También se muestra en la Figura 61, el error cometido en la aproximación de  $\lambda_{SW}$  y  $\lambda_{DC}$ , así como la media del error y su varianza para cada función de peso.

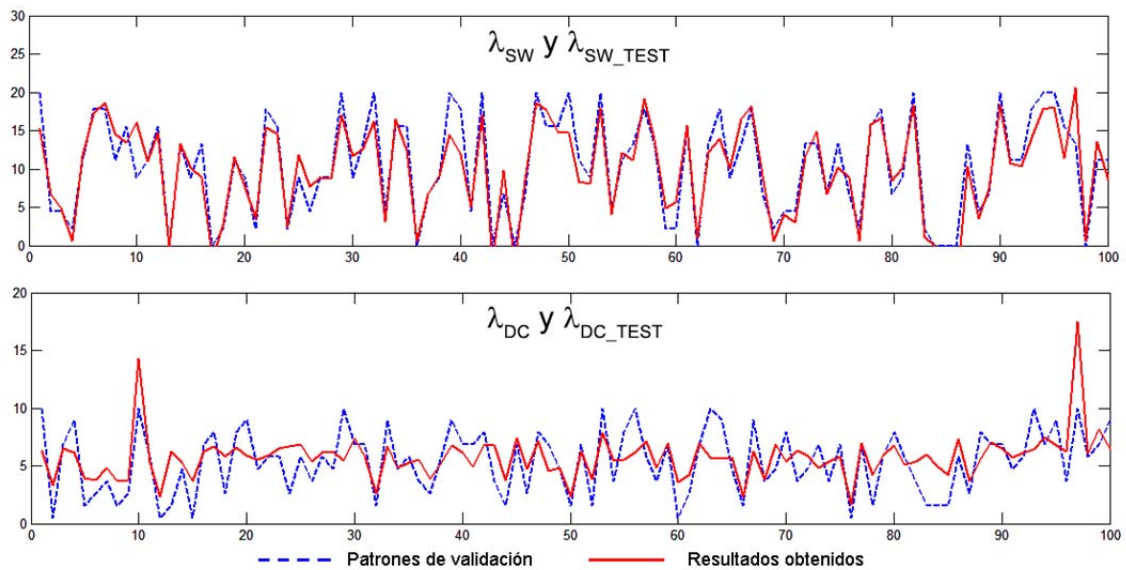


Figura 60. Muestra de resultados obtenidos mediante regresión lineal múltiple.




Figura 61. Error cometido mediante la aproximación por regresión lineal múltiple.

Este método de aproximación tiene una gran ventaja sobre cualquier otro, y es que, para este caso, con tan solo 12 multiplicaciones y 12 sumas (o restas si el coeficiente es negativo), se puede implementar un modelo que realice la regresión lineal múltiple.

### 3.4.2 Redes neuronales artificiales

Las redes neuronales artificiales o ANN (Artificial Neural Network), pretenden imitar el funcionamiento del sistema nervioso de los seres vivos. Son un paradigma de aprendizaje que resulta útil para modelar el comportamiento de sistemas no lineales en los que se desconoce, de manera explícita o matemática, la relación que existe entre las entradas y las salidas. Este tipo de modelos no necesita que exista una relación lineal como en el caso de la regresión lineal múltiple. Otra peculiaridad es su implementación puede abordarse únicamente con operaciones MAC. Además, presentan una gran flexibilidad para manejar cambios no demasiado importantes de las entradas, o para interpolar valores para los que no se hayan entrenado. Por todo ello, es una opción válida para modelar la función de adaptabilidad buscada.

La estructura básica de una red neuronal, es la de una sucesión de capas en cascada, compuestas por neuronas que realizan una combinación lineal de las entradas, y generan una salida atendiendo a cierta función de transferencia. Las neuronas están dispuestas en cada capa de tal manera que las salidas de unas, están conectadas con las entradas de otras. Por tanto, el número de capas en cascada, el número de operadores o neuronas en cada una de ellas, y las conexiones entre unas y otras, conforman una estructura única. El diseño y ajuste de la estructura de una ANN, se

realiza de manera empírica hasta dar con una solución suficiente (65). Todos estos aspectos serán tratados de manera detallada en el CAPÍTULO 4, por lo que en este punto nos centraremos en evaluar de forma sucinta los posibles resultados que se puedan obtener.

Cabe destacar que existen diferentes tipos de redes neuronales. La diferencia más sustancial entre ellos, reside en cómo es el flujo de información entre capas, pudiéndose distinguir dos grandes familias de ANN:

- **Redes neuronales de propagación hacia adelante**, conocidas en terminología inglesa como *Feed-Forward Propagation*. Se caracterizan sobretodo porque el flujo de información se produce desde sus entradas, a través de las capas centrales llamadas ocultas, hasta las salidas. En ningún momento existen ciclos o bucles. El modelo de Perceptrón Multicapa es la estructura más utilizada de este tipo de redes debido a su simplicidad y capacidad de modelar comportamientos no lineales. No obstante, el diseño y entrenamiento de estas redes puede llegar a ser una tarea ardua y lenta. Según el Teorema de la Aproximación Universal, se puede aproximar el comportamiento de cualquier función continua dentro de un conjunto acotado cerrado y multidimensional ( $\mathfrak{R}^n$ ), mediante una red neuronal de propagación hacia adelante con una capa de entrada, una capa oculta con N neuronas, y una única capa de salida (66). Por todo ello, es que este tipo de redes son muy utilizadas para aproximar funciones.
- **Redes neuronales recurrentes** o dinámicas, conocidas en su denominación inglesa como *Feed-Backward propagation*. Son redes que se caracterizan porque realimentan ciertos valores de entradas o salidas, para obtener las salidas futuras. Por este carácter, se dice que este tipo de redes tiene capacidad de predecir el valor futuro de las salidas. Este tipo de redes neuronales, poseen un mayor grado de adaptabilidad ante cambios, y además el algoritmo de entrenamiento suele converger más rápidamente. El principal problema, es que solo son adecuadas para variables que tengan una dependencia temporal, cosa que no parece suceder en nuestro caso.

En este apartado, se muestran los resultados de dos redes neuronales, una de cada tipo. Las redes fueron generadas, entrenadas y testeadas utilizando la *toolbox Neural Network* (65) de MATLAB y su aplicación **nnstart** que permite obtener resultados de

una forma rápida y sencilla. Lo que se pretende es evaluar su capacidad para resolver el problema planteado en esta tesis.

La estructura básica de una red neuronal artificial es la de Perceptrón Multi-Capa, en la que, lo mínimo es tener 3 capas o niveles. Un primer nivel o capa de entrada, que en nuestro caso contará con 6 entradas, a saber, las consignas de potencia y los objetivos de control, en forma de índices de calidad. Una capa oculta intermedia con un número N de neuronas que son las que ayudan a modelar el comportamiento que debe existir entre las entradas y las salidas. Y una última capa de salida con una neurona por cada salida del sistema, en este caso serán 2, correspondientes a los 2 pesos de la función de optimización.

La Figura 62 muestra la estructura de la ANN de propagación hacia adelante que se ha simulado en este apartado. Como se observa, es una red neuronal con 5 neuronas en su capa intermedia u oculta, y el flujo de datos siempre va desde la entrada a la salida sin ninguna dependencia temporal.




Figura 62. Estructura de una red neuronal de propagación positiva de una capa oculta con 5 neuronas.

Después de completar el entrenamiento con la aplicación específica de MATLAB, a la red entrenada se le aplicaron las entradas correspondientes a los patrones de validación  $\vec{X}_{TEST}$  de la base de datos, obteniéndose unos valores  $\vec{Y}'$  los cuales se compararon con los resultados esperados de  $\vec{Y}_{TEST}$ , mostrándose en la Figura 63 los resultados de los primeros 100 patrones de validación.

El comportamiento de estas redes se ajusta al resultado que se pretende, ya que es capaz de aproximar las relaciones entre las entradas y las salidas. Esto se contrasta si se observa la Figura 64, en la que se muestran los valores absolutos de los errores cometidos. Así mismo, se indica sobre la gráfica la media y varianza de los errores cometidos. Esta gráfica demuestra lo que ya se intuye en la Figura 63, y es las redes



neuronales de propagación hacia adelante logran aproximar en gran medida el comportamiento del sistema.




Figura 63. Resultados de la validación de la red neuronal de propagación hacia adelante con una capa oculta de 5 neuronas.




Figura 64. Errores cometidos usando la red neuronal de propagación hacia adelante con una capa oculta de 5 neuronas.

El proceso de entrenamiento de estas redes, busca la minimización del error cuadrático medio cometido o MSE (Mean Square Error) y existen varios algoritmos que se pueden utilizar para realizar el entrenamiento de las redes, por citar algunos:

- Algoritmo de Regiones de Confianza
- Algoritmo Levenberg-Marquardt (LMA o Levenberg-Marquardt Algorithm)
- Conjunto Activo
- Cuadrados mínimos lineales con restricciones
- Cuadrados mínimos lineales no negativos

De entre todos estos métodos, el algoritmo de entrenamiento de Levenberg-Marquardt es el más utilizado para entrenar este tipo de redes neuronales, debido a que tiene un tiempo de convergencia más pequeño en el entrenamiento (67). Su funcionamiento simplificado se basa en una serie de iteraciones, donde los patrones de entrenamiento se aplican a la estructura de red neuronal, y se comparan los resultados finales obtenidos con los valores es. Se deben dividir los patrones en dos grupos: uno para realizar el entrenamiento, y otro más pequeño para realizar una validación. Con el resultado de esta validación, se van corrigiendo (aumentando o disminuyendo) los factores multiplicativos, de tal manera que se reduzca el MSE. Cuando se llega al punto en el que el MSE no mejora, se considera que la red está lo mejor entrenada posible para la topología elegida, finalizando el proceso de entrenamiento. Esta evolución se muestra en la Figura 65, donde se indica, en función del número de iteraciones de entrenamiento o *epochs*, la evolución del MSE durante el proceso de entrenamiento.




Figura 65. Evolución de la etapa de entrenamiento de la red neuronal de propagación hacia adelante con una capa oculta de 5 neuronas.

Otra manera de evaluar el rendimiento de esta red, es estudiando el histograma de errores mostrado en la Figura 66. En ella aparece la relación del número de errores cometidos durante la fase de entrenamiento, validación interna y testeo. Además, la utilidad de estas gráficas es que no solamente se puede ver el número de errores, sino también el valor medio de los errores cometidos, y la magnitud de los mismos. Para esta red, se puede ver como el mayor número de errores cometidos ocurre con una magnitud próxima al propio valor de la media.




Figura 66. Histograma de errores cometidos durante el proceso de entrenamiento de la red neuronal de propagación hacia adelante con una capa oculta de 5 neuronas.

Se puede realizar una estimación del número de operaciones que se necesitan para implementar este tipo de redes, dependiendo del número de capas. Sin embargo, se puede afirmar que los recursos consumidos para implementar esta solución, pasan por ser los más altos de entre todas las posibles soluciones. Si por ejemplo se miden los recursos consumidos por cada solución, evaluando el número de operaciones que se necesitan para ser implementadas, para el caso de una red con la estructura de Perceptrón Multi-capas de 5 neuronas en su capa oculta, se necesitan realizar unas 40 multiplicaciones y 40 sumas cada vez que se modifique alguna entrada para obtener los factores de peso  $\lambda_{DC}$  y  $\lambda_{SW}$ . Este número de operaciones aumenta progresivamente a medida que aumenta también el número de neuronas de la capa oculta de la red.

Si comparamos estas operaciones con el caso de la regresión lineal múltiple, en la que solo se necesitaban realizar unas 12 sumas y 12 multiplicaciones, se pone de manifiesto que las redes neuronales necesitan más recursos aunque con ellas se obtengan mejores resultados.

En cuanto a las redes neuronales recurrentes, aparte de poder cambiar el número de capas y el número de neuronas, también se pueden especificar relaciones temporales

entre diferentes neuronas. Esto indica que ya no solamente las salidas de las neuronas de una capa anterior sirven como entradas para las de la de cierta capa, sino que se pueden usar como entradas, valores anteriores en el tiempo de otras neuronas. Si esto ocurre, existirán ciclos o bucles en el flujo de información de los datos, y la red neuronal utilizará los valores anteriores en el tiempo para predecir los futuros. Esta peculiaridad hace que sean métodos útiles cuando se tienen entradas que dependan del tiempo  $\vec{X}(t)$ . No obstante, las entradas  $P$ ,  $Q$ ,  $\Delta i \alpha \beta$ ,  $THD$ ,  $\Delta V_c$  y  $f_{sw}$  son consignas que se pueden cambiar en cualquier momento, pero no dependen del tiempo como es el caso de las corrientes o tensiones de red. Por tanto, a priori, este tipo de redes no resultan adecuadas para el caso bajo estudio. Para comprobarlo se diseñó una red neuronal recurrente con una capa oculta de 15 neuronas, y una dependencia temporal de un nivel de la propia salida de la red, es decir que dependerá de  $\vec{Y}(t - 1)$ . Esta estructura se muestra gráficamente en la Figura 67. Este tipo concreto de redes se conocen por el nombre de redes auto-regresivas, debido a que la salida depende de valores anteriores de ella misma.




Figura 67. Estructura de una red neuronal recurrente de una capa oculta con 15 neuronas y una dependencia temporal de una muestra.

Después de entrenar la red mediante MATLAB, los resultados que se obtienen al aplicarles los patrones de validación se muestran en la Figura 68 y Figura 69. En ellos se observa que la salidad de este tipo de red tiene un elevado nivel de error. Ello se debe a que, al tener una estructura recurrente, durante el proceso de entrenamiento, se fuerza el aprendizaje indicando que la salida actual  $\vec{Y}(t)$  depende de  $\vec{Y}(t - 1)$ , cosa que como ya se ha dicho, no coincide con la realidad. Si no se realiza un proceso de aprendizaje consistente con la relación real entre entradas y salidas, la ANN no tiene ninguna utilidad, pues sería como enseñarle a un niño el color rojo mostrándole objetos amarillos.




Figura 68. Resultados de la validación de una red neuronal recurrente de una capa oculta con 15 neuronas y una dependencia temporal de una muestra.




Figura 69. Errores cometidos usando la red neuronal recurrente de una capa oculta con 15 neuronas y una dependencia temporal de una muestra.

Si vemos el histograma de errores cometidos por esta red, mostrado en la Figura 70, se observa una gran diferencia respecto al de las redes neuronales con propagación hacia adelante. No solamente los errores que se cometen son mayores, sino que ocurren en mismo número los de pequeña como de gran magnitud.




Figura 70. Histograma de errores cometidos durante el proceso de entrenamiento de una red neuronal recurrente de una capa oculta con 15 neuronas y una dependencia temporal de una muestra.

En cambio, estas redes tienen un entrenamiento mucho más rápido, ya que el proceso converge mucho más rápidamente que en el caso de redes con propagación hacia adelante, aunque con peor MSE, tal como se indica en la Figura 71 que muestra la evolución del mismo durante el entrenamiento.




Figura 71. Evolución de la etapa de entrenamiento de la red neuronal recurrente de una capa oculta con 15 neuronas y una dependencia temporal de una muestra.

### 3.4.3 Lógica difusa

La lógica difusa es una técnica que consiste en aproximar el comportamiento de sistemas complejos (en los que a priori se renuncia a obtener un modelo matemático), mediante la aplicación de un conjunto de reglas de inferencia basadas, normalmente, en la experiencia previa de un experto (68).

En este tipo de método, se definen cuantificadores no numéricos para definir los diferentes estados en los que puedan estar las variables, y posteriormente aplicando las reglas conocidas como de inferencia, se obtienen las decisiones o salidas.

Por ejemplo, supongamos un caso muy simple en el que conociésemos como debe ser el valor de  $\lambda_{DC}$  respecto a la variación de la potencia reactiva  $Q$ . Se podrían definir tres cuantificadores verbales para describir la  $Q$  que se introduce en la red: “baja”  $Q$ , “media”  $Q$  o “alta”  $Q$ . Para realizar esta cuantificación, se aplican lo que se conocen con el nombre de funciones de pertenencia. Así como en la lógica clásica, las



operaciones pueden tener resultados de verdadero/falso o 1/0, en la lógica difusa las variables o condicionantes pueden tomar estados intermedios entre el verdadero/falso, todo/nada, 0/1. En la Figura 72, se muestran dos ejemplos de definiciones de funciones de pertenencias para definir los tres cuantificadores de la potencia reactiva Q.




Figura 72. Ejemplo de dos funciones de pertenencia para el caso de clasificación de la potencia reactiva Q en lógica difusa.

Como se observa en la figura, para un punto concreto de potencia reactiva Q, según la función de pertenencia, las condiciones de clasificación pueden ser más o menos drásticas, así por ejemplo en el caso inferior, está mucho más claro que la potencia se considera “media” al tomar un valor muy próximo a “1” o “verdadero”.

De la misma manera, se podrían definir tres niveles para el factor de peso  $\lambda_{DC}$ : un “alto”  $\lambda_{DC}$ , “medio”  $\lambda_{DC}$  y un nivel “bajo” de  $\lambda_{DC}$ . A este proceso de clasificación se le conoce como *fuzzyficación* (de *fuzzy* o difuso en inglés). Definidos los conjuntos, en base a las observaciones o resultados previamente evaluados del sistema, se podrían construir reglas de inferencias del tipo:

$$Si (ANTECEDENTES), entonces (CONSECUENTES) \quad [ 59]$$

Por ejemplo:

- Si hay “baja” potencia Q, entonces  $\lambda_{DC}$  deberá ser “medio”.
- Si hay “media” potencia Q, entonces  $\lambda_{DC}$  deberá ser “medio”

- Si no hay “alta” potencia  $Q$ , entonces  $\lambda_{DC}$  deberá ser “alto”.

Como se puede deducir del ejemplo anterior, el primer problema que se establece con este método, es que se necesita formalizar adecuadamente las reglas de inferencia, y para hacerlo, se debe contar con un número suficiente de observaciones del comportamiento. Además, se debe hacer ver que en el ejemplo propuesto solo intervienen una variable de entrada con un variable de salida, no obstante, en el sistema a implementar existirían múltiples variables de entrada, y múltiples dependencias. La complejidad pues de obtener las reglas, se incrementa considerablemente.

Una solución muy usada para establecer las reglas de inferencia en sistemas complejos como el aquí estudiado, es utilizar una red neuronal artificial que tome las decisiones.

Otro inconveniente, es que las salidas también forman parte de conjuntos difusos, es decir, que si en el ejemplo planteado, la  $\lambda_{DC}$  deba ser “alta”, a efectos computacionales para la función de coste del Control Predictivo, no es un resultado válido, ya que este debe realizar operaciones matemáticas con él, y el valor “alto” no aplica. Para estos casos en los que no basta con que el resultado se cuantifique de manera difusa, se pueden usar relaciones entre un valor concreto y un cuantificador de la lógica difusa; no obstante, es posible que dependiendo del sistema, se necesite aumentar el rango de posibles cuantificadores tanto para las salidas como para las entradas. Por ejemplo: un valor “muy alto” de  $\lambda_{DC}$  equivaldría a usar  $\lambda_{DC}=2.5$ , un valor “alto” a  $\lambda_{DC}=2$ , un valor “medio-alto” a  $\lambda_{DC}=1.5$ , un valor “medio” a  $\lambda_{DC}=1$ , y así sucesivamente. Nótese que al aumentar el número de cuantificadores, se incrementa proporcionalmente el número y complejidad de las reglas de inferencia.

Por todos los problemas que plantea la lógica difusa, se ha descartado para el caso del algoritmo A-MPC.

### **3.5 Selección del método para ajuste del controlador A-MPC.**

Realizando una recopilación de los resultados obtenidos para los diferentes métodos vistos para aproximar la función de adaptabilidad, se dispondrá de una visión de conjunto para decidir cuál resulta adaptarse mejor al caso de ajuste del controlador A-MPC. En la Tabla 23 se muestran estos datos.

Tabla 23. Resultados obtenidos para las posibles soluciones de aproximación de la función de adaptabilidad.

Método de aproximación	Error medio $\lambda_{DC}$	Varianza del error $\lambda_{DC}$	Error medio $\lambda_{SW}$	Varianza del error $\lambda_{SW}$	Número de Operaciones
Regresión Lineal Múltiple	1.89	1.85	1.79	2.19	$12\oplus, 12\otimes$
Feed-Forward ANN	0.83	0.53	1.04	0.75	$8\cdot N\oplus, 8\cdot N\otimes$ N: número de neuronas c.o.
Feed-Backward ANN	2.62	2.3	5.48	10.8	$9\cdot N\oplus, 9\cdot N\otimes$ N: número de neuronas c.o.

En base a los resultados obtenidos, se ha decidido implementar la solución mediante una red neuronal artificial de propagación hacia adelante, que para simplificar, denominaremos por sus siglas en inglés **FF-ANN**.

### 3.6 Conclusiones

Según el estudio realizado en este capítulo, se pueden obtener las siguientes conclusiones:

- Se han definido 4 parámetros de calidad principales para evaluar el comportamiento del sistema: error medio de tracking, distorsión armónica total media, desequilibrio del Bus-DC y frecuencia media de conmutación de los IGBT. Así mismo, se han obtenido los rangos admisibles de estos parámetros.
- Se han establecido los márgenes de operación del convertidor en cuanto a las consignas de potencia, y a continuación se ha creado un espacio de observaciones con múltiples experimentos para un conjunto de valores pertenecientes a dichos márgenes, utilizando diferentes factores de peso de la función de coste.
- Se ha estudiado la relación existente entre las consignas y los factores de pesos de la función de coste, en relación a los parámetros de calidad del sistema, llegándose a la conclusión que estas dependencias no son triviales y se necesitan métodos de aproximación.

- Se ha definido la funcionalidad principal del Algoritmo de Control Predictivo Adaptativo o A-MPC, como la solución para hacer que el sistema se adapte ante cambios de consignas, y modifique automáticamente los factores de peso  $\lambda_{DC}$  y  $\lambda_{SW}$  de la función de coste.
- Por último, se han estudiado diferentes alternativas para aproximar el comportamiento obtenido, encontrando finalmente la aproximación mediante una red neuronal artificial de propagación hacia adelante multi-capa como la mejor solución para el caso abordado.

# CAPÍTULO 4. PROPUESTA DE IMPLEMENTACIÓN DE LA ESTRATEGIA DE OPTIMIZACIÓN

La propuesta que se realiza en esta tesis, pasa por modelar el comportamiento del convertidor junto con el algoritmo de Control Predictivo, mediante una red neuronal FF-ANN entrenada *off-line* a partir de los resultados experimentales o simulados obtenidos con anterioridad. Se ha elegido la implementación mediante una red neuronal, debido a que es una solución de baja complejidad matemática y que no añade un retardo significativo al controlador, siempre que se encuentre convenientemente entrenada y caracterizada (46) (47). Con las relaciones entrada-salidas obtenidas en los experimentos de caracterización del sistema, se obtienen los patrones de entrenamiento para la red neuronal.

La Figura 73 muestra el esquema del controlador basado en el algoritmo A-MPC, sobre el que se ha desarrollado una FF-ANN como método para ajustar los pesos de la función de coste, cuando hay un cambio en las referencias de potencia o índices de calidad deseados para el sistema.

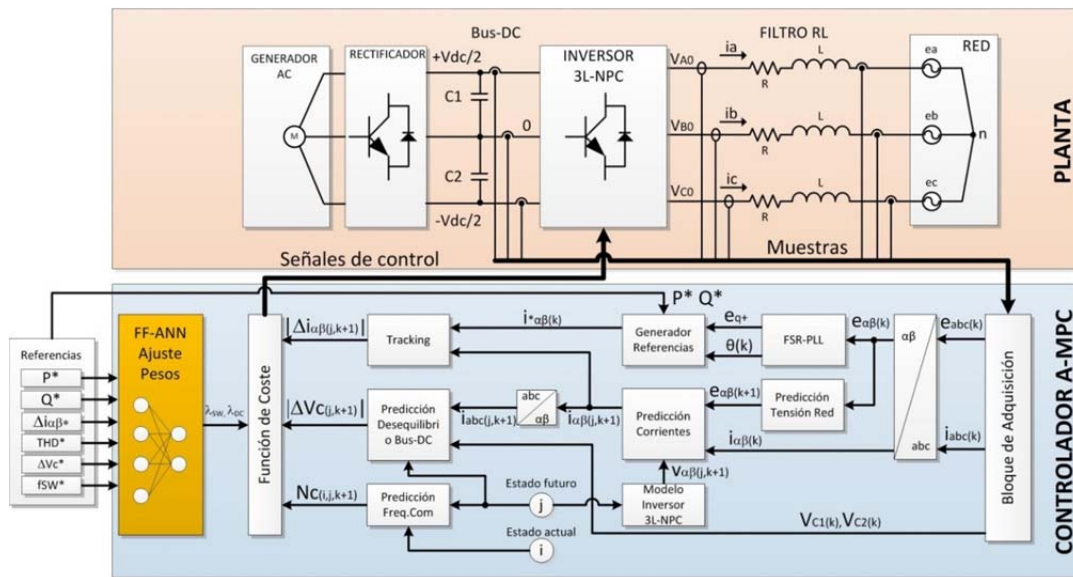


Figura 73. Diagrama de bloques del Algoritmo de Control Predictivo Adaptativo usando una red neuronal artificial para el ajuste de los pesos de la función de coste.

## 4.1 Modelo genérico de red neuronal Perceptrón Multicapa

Una red neuronal artificial consta en su forma más simple, de un conjunto de neuronas artificiales o elementos de proceso, contenidas en diferentes capas de abstracción. Si la información fluye únicamente desde las entradas hacia las salidas, a la red neuronal se le conoce como “*de propagación hacia adelante*” o FF-ANN de sus siglas en inglés. La estructura más usada para las FF-ANN, es la del Perceptrón Multicapa, denominado así por estar compuesto por múltiples capas en cascada, cada una de ellas con una o varias neuronas, en las que las entradas provienen de las salidas de la capa anterior. Como se indicó en el capítulo anterior, el Teorema de Aproximación universal asegura que una estructura mínima de Perceptrón Multicapa, puede aproximar cualquier función continua multidimensional en un conjunto acotado y cerrado.

El número de capas mínimas de un Perceptrón Multicapa son tres: una de entrada, una capa intermedia u oculta y una capa de salida. Además de este diseño simple, las redes neuronales artificiales pueden concebirse como estructuras multicapa, en las que en cada una de ellas existe un determinado número de neuronas artificiales. En la Figura 74 se muestra un esquema de la estructura básica de una red neuronal artificial Perceptrón Multicapa.

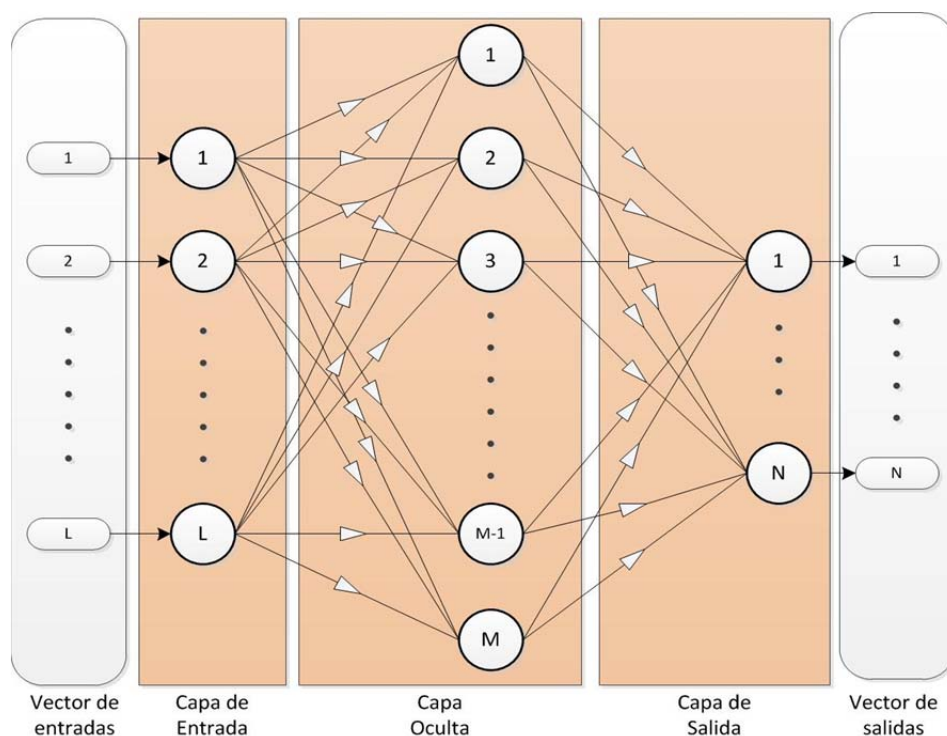


Figura 74. Estructura básica de una FF-ANN Perceptrón Multicapa.

En la figura anterior, se observa cómo las neuronas (bloques circulares), se interconectan con las neuronas de la capa precedente y posterior, mediante un peso determinado. Como se verá posteriormente, estos pesos son factores multiplicativos que representan cuantitativamente la importancia de la relación entre una neurona y otra, y encontrar sus valores es la función principal del proceso de entrenamiento o aprendizaje de las ANN. Lo normal, es que entre cada par de neuronas de una capa  $N$  y su predecesora  $N-1$ , exista una conexión mediante un peso concreto, no obstante, hay diseños en los que, una vez realizado el entrenamiento, se eliminan las interconexiones cuyos pesos que tienen a cero.

#### 4.1.1 Modelo de perceptrón o neurona artificial

Por su parte, una neurona artificial o perceptrón, se define como un elemento de proceso que realiza una operación lineal o no, sobre el vector de entradas, para obtener una salida que será, a su vez, parte de un vector de entradas para una neurona de la siguiente capa.

La operación principal de una neurona está descrita por la aplicación de una *función de propagación*, seguida de una *función de transferencia*. La función de propagación describe el proceso que se le aplican a las entradas, mientras que la función de transferencia describe el proceso aplicable a la salida y entrada de la siguiente capa. Este modelo, está basado en el símil biológico, en el cual una neurona tiene múltiples canales de entradas, llamadas *dentrías*, y un único canal de salida, llamado *axón*, que se comunica con la entrada de otra neurona (65). En la Figura 75, se muestra la estructura básica de una neurona artificial, cuya función de propagación está compuesta por una combinación lineal de las entradas, y a la salida se le aplica la función de transferencia  $f(x)$ .




Figura 75. Estructura de una neurona artificial y su equivalente biológico.

La función de propagación  $fp(t)$  se define formalmente como:

$$fp(u) = \sum_{i=1}^N u_i \cdot w_i + b \quad [60]$$

en la que  $u$  es el vector de entrada de  $N$  valores o componentes,  $w$  es el conjunto de  $N$  factores multiplicativos o pesos (uno para cada entrada) y  $b$  representa un término de corrección o desplazamiento que puede ser sumado como un *offset* o *bias* sobre la operación lineal.

En cuanto a la función de transferencia  $ft(x)$ , su objetivo principal es la de limitar o acotar los valores que se tienen a la salida. Como la operación completa de una FF-ANN, se basa en realizar multiplicaciones y sumas sobre valores, estos tenderán finalmente a crecer a medida que van atravesando las diferentes capas del diseño. Debido a esto, se aplican funciones que limiten ese crecimiento. Existen diferentes tipos de funciones de transferencia diseñadas para cumplir este objetivo. Algunas de las más utilizadas son:

- Lineal:  $ft(x) = x$
- Log-Sigmoidal:  $ft(x) = \frac{1}{1+e^{-x}}$
- Tan-Sigmoidal:  $ft(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$
- Rectificador:  $ft(x) = \max(0, x)$

Finalmente, se puede describir el proceso completo de una neurona artificial según:

$$Salida = ft \left[ \left( \sum_{i=1}^N u_i \cdot w_i \right) + b \right] \quad [61]$$

#### 4.1.2 Entrenamiento de un Perceptrón Multicapa

Las redes neuronales se deben "entrenar", ajustando los pesos de las interconexiones neuronales, para que caractericen o describan el comportamiento de un sistema. Para ello, se sigue un proceso iterativo de minimización del error que la red comente cuando se le presentan los patrones de entrenamiento.

Se parte de valores cualesquiera para los pesos  $w_i$  de cada neurona. Pueden elegirse manualmente antes del entrenamiento, aunque normalmente se obtienen mejores



resultados cuando se parten de valores aleatorios tal como se explica en (65) o en (69). El caso ideal para la inicialización de los pesos es cuando se le asignan valores lo más próximos posibles a los valores que deberán tener finalmente tras el entrenamiento, sin embargo, en la mayoría de los casos prácticos, esta condición es imposible de llevar a cabo a priori, y solo se podría aplicar si se tiene la red pre-entrenada con un comportamiento muy próximo al deseado. El proceso comienza aplicándole a la red neuronal un patrón de entrenamiento, o colección de entradas para las que se conocen las salidas correctas. Con los pesos iniciales, se calcula el error cuadrático medio cometido en la salida, y mediante un proceso de corrección que minimiza el gradiente de la función resultante de componer las operaciones que realizan todas las neuronas, se le suma o resta cierto valor a cada peso y *bias* con objeto de obtener un menor error la próxima vez.

Este proceso se repite con cada uno de los diferentes patrones de entrenamiento de entradas-salidas, y con cada uno se monitoriza el error cometido con los pesos actuales. Al terminar con todos los patrones de entrenamiento, el algoritmo ajusta los pesos y se repite el proceso nuevamente con todos los patrones y los nuevos pesos, comenzado lo que se conoce como una nueva iteración o *epoch* en inglés.

Existen diferentes tipos de algoritmos de entrenamiento, en cuanto a la manera de realizar el entrenamiento supervisado de la red, la corrección de los pesos y el método de optimización (65). Algunos de los más usados son el algoritmo de Levenberg-Marquardt o el de Descenso de Gradiente con Momento. En este caso se ha realizado todo este proceso de entrenamiento mediante al algoritmo Levenberg-Marquard o LMA (Levenberg-Marquardt algorithm), el cual es muy fácil de aplicar en redes FF-ANN (70).

La base principal de este algoritmo, es encontrar el conjunto de factores multiplicativos  $\omega$  de la ANN para que se minimice el error cuadrático medio para un conjunto de ' $m$ ' resultados conocidos de entrada-salida o patrones  $(x_i, y_i)$ , de cierta función  $F(x)$  de la cual se realiza la aproximación. En la ecuación [ 62] se muestra la condición principal a resolver por el algoritmo de entrenamiento, en el que se deben encontrar los pesos que minimicen el MSE.

$$\omega = \min \left( \sum_{i=1}^m (y_i - F(x_i, \omega))^2 \right) \quad [ 62]$$

Los pesos  $\omega$  se van ajustando en cada iteración añadiéndoles cierto ajuste  $\delta$ , para quedar como  $\omega + \delta$  donde dichos ajustes, se obtienen mediante la aproximación [ 63]

$$F(x_i, \omega + \delta) \approx F(x_i, \omega) + \frac{\partial F(x_i, \omega)}{\partial \omega} \cdot \delta \quad [ 63]$$

siendo  $\frac{\partial F(x_i, \omega)}{\partial \omega}$  el gradiente de la función respecto a los pesos  $\omega$  y que finalmente se traduce en una matriz jacobiana. El error cuadrático medio será mínimo cuando el gradiente de la anterior expresión sea prácticamente nulo. El proceso para conseguir anular el gradiente es la verdadera contribución del algoritmo LMA, el cual escapa a los objetivos de esta tesis. Sin entrar en detalles, conviene indicar solamente que en este caso, se sigue un proceso conocido como de propagación inversa o Back-propagation, en el cual se intenta minimizar las derivadas parciales de la matriz jacobiana desde los pesos de las neuronas de la salida, hasta los de las entradas (de ahí el título de propagación inversa).

Si la red aprende adecuadamente, este error disminuye a medida que se incrementa el número de iteraciones en el entrenamiento. Este proceso debe realizarse con cuidado de no sobreentrenar la red. Existen dos alternativas a la hora de establecer cuándo se aplican los cambios a los pesos y *bias*.

- Modo incremental: en el que después de aplicar cada patrón se actualizan los valores y así durante todas las iteraciones. Es un método aconsejable solo para redes neuronales de dimensiones reducidas, ya que es un algoritmo lento, al realizar las operaciones patrón por patrón.
- Modo *batch*: después de terminar cada iteración, es cuando se actualizan los valores. Este método es más rápido y evolucionado que el anterior, el tiempo de entrenamiento se reduce drásticamente y se obtienen mejores resultados cuando se tienen redes neuronales de tamaño mediano o grande.

También hay dos maneras de realizar el aprendizaje de las redes neuronales en cuanto a los datos que se usan para hacerlo: supervisado, y no supervisado. Los métodos supervisados son aquellos que necesitan un conjunto previo de datos cuidadosamente seleccionados, en los que, para cada entrada, se conoce el resultado. Mientras, los métodos no supervisados no necesitan dicho conjunto, y se entrenan observando directamente la relación entrada-salida durante el funcionamiento de un sistema. Este último implica que la red neuronal se va entrenando a medida que va conociendo nuevos patrones de entrada-salida y es una buena opción cuando se tiene

sistemas que necesiten adaptarse a nuevas situaciones. Para el caso que nos ocupa, los rangos de entrada y salida están bien delimitados y son conocidos por lo que para el Perceptrón Multicapa que se desea implementar, resulta conveniente el aprendizaje supervisado

Un hecho que hay que evitar cuando se entrenan las ANN es el sobre-entrenamiento, que se puede producir por dos causas principales. La primera es cuando se entrena la red durante demasiadas iteraciones con los mismos patrones. La segunda causa es cuando se seleccionan demasiados patrones dentro de la base de datos de observaciones para realizar el entrenamiento. En ambos casos el efecto es el mismo: la red neuronal se adaptará para minimizar solamente el error de los patrones con los que se le ha entrenado, y cuando se le aplique un patrón que no esté incluido en el entrenamiento, la red no tendrá capacidad de generalizar y proporcionar, así, un resultado adecuado. Para evitarlo, se establecen mecanismo de finalización, cuando después de varias iteraciones, no se consigue mejorar sustancialmente el MSE.

Finalmente, si los patrones de entrada-salida con los que se entrena la red son adecuados, y el algoritmo de entrenamiento y la estructura de la red neuronal también lo son, se puede conseguir una red neuronal entrenada para modelar el comportamiento del sistema. En este trabajo se realizará el entrenamiento mediante la *toolbox* Neural Network de MATLAB.

#### **4.1.3 Problemas asociados**

El principal inconveniente del uso de redes neuronales artificiales, es la ausencia de un procedimiento sistemático para escoger la arquitectura de la red y la técnica de entrenamiento. El número de neuronas de la capa oculta, el tipo de la función de transferencia, el número de capas ocultas, la realimentación o no, el número de iteraciones en el entrenamiento, el objetivo de error mínimo, la cantidad y calidad de los patrones entrada-salida para que no se produzca sobre-entrenamiento, son algunas de las cuestiones que han de ser resueltas mediante la experimentación para cada caso de estudio en concreto.

Otro problema que plantean las ANN, es la cantidad de recursos que se necesitan para implementarlas y entrenarlas. En función del tamaño de la red, esta tarea puede recaer en unidades de procesamiento aceleradas, como es el caso del uso de unidades de procesamiento gráfico o GPUs, presentes en las tarjetas gráficas. La

mayoría de entornos de desarrollo, como MATLAB, son compatibles con el uso de GPU.

## **4.2 Diseño y entrenamiento de la red neuronal para el caso de estudio**

Según lo visto en el punto anterior, el diseño y entrenamiento de una red neuronal lleva implícito una serie de decisiones que no están sujetas a reglas determinísticas. Se trata de encontrar un equilibrio entre las necesidades o requisitos y el buen comportamiento que se quiera de la red neuronal. La mejor manera de encontrar este equilibrio, debido a la complejidad de la evaluación del modelo, y la infinidad de variables que intervienen, es mediante la experimentación y comprobación de los resultados.

Para el caso que nos ocupa, lo primero que se tiene que tener en cuenta es que la implementación de la red neuronal debe ser lo más sencilla posible computacionalmente hablando, para minimizar los recursos necesarios y el retardo que introduzca en el controlador del inversor.

Existen diferentes tipos de redes neuronales: Perceptrón, Adaline, Perceptrón Multicapa, Elman, Hopfield, etc. Cada una de ellas tiene una peculiaridad concreta y un modelo de actuación diferente. Para el caso del sistema que se desea modelar, se ha decidido usar el Perceptrón Multicapa, debido a diferentes razones. Primeramente, estos tipos de redes neuronales, son capaces de simular comportamientos de sistemas que no son linealmente aproximables, de una manera sencilla y estructurada en capas con operaciones matemáticas simples (MAC). Además, es un tipo de red de propagación hacia adelante, por lo que no intervienen valores pasados de las salidas y por tanto no hay bucles. Todo ello hace que la implementación en FPGA sea factible, puesto que las operaciones son directamente sintetizables en lógica programable, y se puede realizar una segmentación de la ejecución por etapas, coincidiendo con la ejecución por capas de la propia red.

Lo segundo que se debe tener en cuenta es la creación de los patrones de entrenamiento adecuados para la red neuronal. Para ello, se dispone en este caso de la base de datos obtenida mediante el procedimiento explicado en el punto 3.3, con multitud de resultados que describen las relaciones entre los parámetros de entrada y

salida. Aun teniendo una estructura de red adecuada, y aplicando un algoritmo de entrenamiento eficaz, la eficacia del entrenamiento depende en gran medida de la base de datos utilizada, la cual deberá contemplar todo el rango de variación posible de las entradas, y haber sido entrenada con el mayor número de casos diferentes sin redundancia para aproximar la función deseada.

De todos los patrones obtenidos en la base de datos, el 80% se han reservado para los procesos de entrenamiento, reservando un 20% de patrones para una validación final ajena al entrenamiento. Para la creación, entrenamiento y simulación de la red neuronal, se puede usar una librería de funciones, como por ejemplo la *toolbox* Neural Network de MATLAB.

#### 4.2.1 Creación de la red neuronal

Según el modelo general del Perceptrón Multicapa mostrado en la Figura 74, las entradas de la red neuronal serán las referencias de potencia del controlador A-MPC y los objetivos de control (índices de calidad deseados), es decir:

- Potencia activa de referencia:  $P$
- Potencia reactiva de referencia:  $Q$
- Desviación media de corriente:  $\Delta i_{\alpha\beta}$
- Distorsión armónica total media:  $THD$
- Desequilibrio medio del Bus-DC:  $\Delta V_c$
- Frecuencia media de conmutación:  $f_{SW}$

Las salidas de la red neuronal serán los dos pesos de la función de coste:

- Factor de peso del desequilibrio del Bus-DC:  $\lambda_{DC}$
- Factor de peso de la frecuencia de conmutación:  $\lambda_{SW}$

Por tanto, la red neuronal tendrá **6 entradas** y la capa de salida tendrá **2 neuronas**, correspondientes a los dos pesos de la función de coste de optimización del controlador. La estructura general de la ANN deberá ser como la mostrada en la Figura 76.

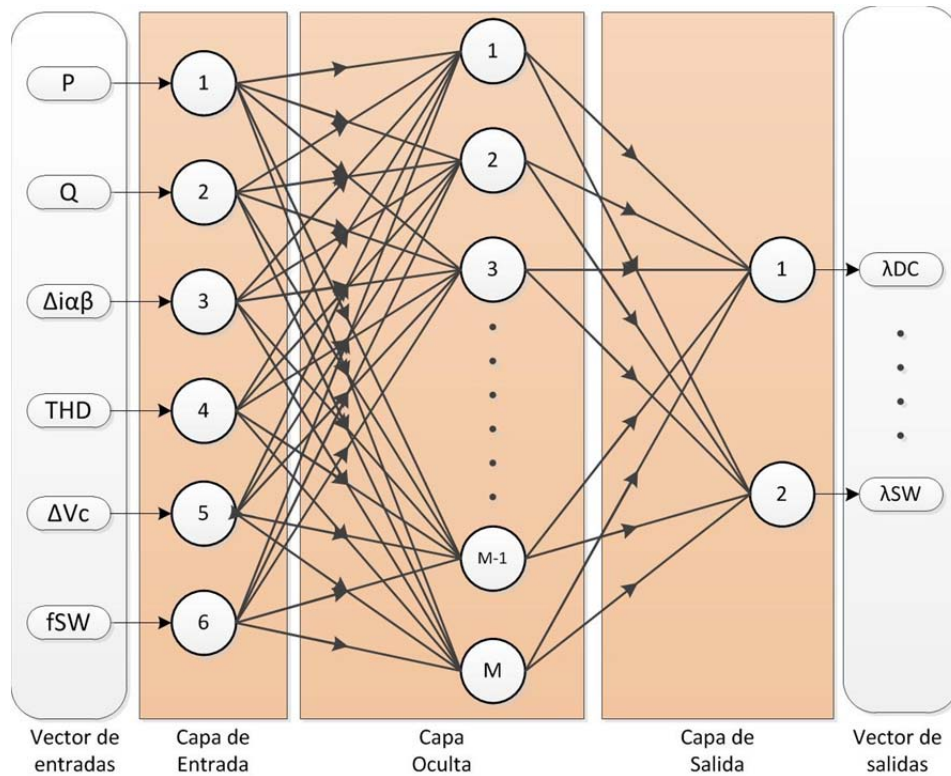


Figura 76. Diseño genérico de la FF-ANN Perceptrón Multicapa para modelar el comportamiento del algoritmo A-MPC.

Los rangos de valores de las entradas, coinciden con los márgenes de valores de los objetivos de calidad del sistema, junto con las posibles configuraciones de potencia admisibles para el inversor que se usa. Resumiendo y agrupando lo que se vio en el CAPÍTULO 3, estos rangos quedan:

- $\sqrt{P^2 + Q^2} \leq 100kVA; 0 \leq P \leq 100kW; -100KVar \leq Q \leq 100kVar$
- $0 \leq \Delta i\alpha\beta \leq 25Arms$
- $0 \leq THD \leq 20\%$
- $0 \leq \Delta Vc \leq 12V$
- $0 \leq Freq \leq 2000Hz$

A las entradas de las ANN muchas veces se les suele aplicar un pre-procesamiento con el fin de adecuar las entradas de cara a la implementación de la red. El caso más usado de pre-procesamiento es realizar una normalización de las entradas, para conseguir que todas tengan el mismo rango. No obstante, el principal inconveniente de los pre-procesados es que necesitan realizar operaciones de división (como en el caso de la normalización), las cuales son difíciles de implementar en VHDL sobre una FPGA, más cuando habría que realizar una por cada entrada de la red. En casos más

complejos como en el reconocimiento de imágenes, realizar un pre-procesamiento es obligado para reducir el error de aproximación (71), sin embargo, en estructuras de redes de menores dimensiones, como la utilizada en este caso, no se ha encontrado una variación del error que compense la complejidad de incluir un pre-procesamiento.

Para ajustar el número de neuronas de la capa oculta, existen algunas reglas generales de diseño como, por ejemplo: “El número óptimo de neuronas de la capa oculta ‘M’ suele estar entre el número de neuronas de entrada y el de salida”. No obstante, este tipo de reglas pueden ser pobres y en ocasiones hay que recurrir a otros métodos.

Quizás el mejor método no empírico para encontrar el diseño óptimo de una red neuronal cuando su complejidad es muy elevada, es la aplicación de algoritmos genéticos (72). Estos algoritmos se basan en el comportamiento biológico de selección natural, por el cual se van seleccionando en sucesivas generaciones, aquellos individuos que se adaptan mejor al medio. Para el caso de las redes neuronales, primero se define un conjunto de parámetros que identifican su estructura, como son el número de capas, el número de neuronas, tipo de funciones de activación, entre otros (símil con el genoma) y se selecciona un conjunto inicial aleatorio de posibles soluciones. Posteriormente, se realizan transformaciones sobre este conjunto inicial para dar una nueva generación de soluciones (tras aplicar mutaciones, recombinaciones, etc.). El concepto básico del algoritmo genético es el realizar posteriormente una selección de los mejores nuevos casos encontrados para ser aplicados en la siguiente iteración. El algoritmo termina cuando las generaciones de soluciones converjan en la solución óptima. Este método tiene como mayor desventaja que puede ser difícil definir las reglas óptimas de transformación y selección, pudiendo no encontrarse una convergencia, o tardando demasiado en hacerlo.

Aunque los algoritmos genéticos presentan una solución al problema de encontrar la estructura óptima, debido a que la red definida en esta tesis no tiene gran complejidad, el número óptimo se consiguió mediante experimentación. Para ello, se testearon diferentes casos, en los que se fue aumentando progresivamente el número de neuronas de la capa oculta  $M$ , y en cada una de ellas se evaluó el error cometido por la red. Viendo la progresión del error, se obtiene  $M$  como el número mínimo de neuronas que consigan minimizar el error cometido.

A continuación, se muestra el resultado de la evaluación del error a la salida  $\vec{Y}$  de la red neuronal, con diferentes números de neuronas en la capa oculta, para un conjunto

de entradas o patrones de comprobación  $\vec{X}$  para los cuales se conocen sus salidas, y realizándose un entrenamiento con un número fijo de 500 iteraciones para cada caso. También se muestra la pendiente de la recta de regresión lineal  $R$  que relaciona las salidas reales de la red  $\vec{Y}$  con las conocidas de los patrones de entrenamiento  $\vec{Y}_{TEST}$ . El caso ideal se consigue cuando la salida real es idéntica a la de los patrones, y por tanto  $\vec{Y} = \vec{Y}_{TEST}$  o  $R = 1$ . Por tanto, esta magnitud expresa de manera matemática el grado de similitud que existe en la aproximación que realiza la red.

Tabla 24. Evolución del error cuadrático medio (MSE) y la pendiente de la recta de regresión (R) para diferente número de neuronas de la capa oculta.

Neuronas Capa Oculta (M)	MSE	R	Número de operaciones
1	6.664	0.881	8
2	2.48	0.9572	16
3	1.88549	0.9689	24
4	1.54587	0.97349	32
5	1.54031	0.9737	40
6	1.48253	0.976	48
7	1.43684	0.97689	56
8	1.2843	0.9788	64
9	1.17025	0.980842	72
10	1.19206	0.98077	80
11	1.14096	0.981	88
12	1.37229	0.9768	96
13	1.189	0.9807	104
14	1.18298	0.9798	112
15	1.09321	0.9816	120
16	1.15699	0.9811	128
17	1.23561	0.9793	136
18	1.22532	0.9795	144
19	1.2032	0.9787	152
20	1.19887	0.9788	160
21	1.1889	0.9805	168
22	1.2397	0.9802	176
23	1.258	0.978	184



Asimismo se han evaluado, en una primera aproximación, los recursos que consumirían cada una de las soluciones, teniendo en cuenta el número de operaciones de multiplicación y suma que se deben realizar en cada una de las neuronas. Las neuronas de la capa oculta, implican cada una 6 multiplicaciones (una por cada peso y entrada) y 6 sumas (5 de las salidas de los pesos más una de añadir la *bias*). En cambio, las dos neuronas de la capa de salida (una para cada factor de peso), suponen cada una  $M$  multiplicaciones más  $M$  sumas, donde  $M$  es el número de neuronas de la capa oculta.

La Figura 77 muestra los resultados obtenidos, donde se puede apreciar que a partir de 13 neuronas en la capa oculta, el error permanece estable, consiguiéndose un mínimo para  **$M = 15$  neuronas**. Por ello, este será el número de neuronas seleccionadas para implementar la red neuronal del algoritmo A-MPC.




Figura 77. Gráfica del error cuadrático medio cometido por la red neuronal en función del número de neuronas de la capa oculta, y el valor de la pendiente de regresión  $R$ .

Finalmente, la red neuronal que se implementará tiene una estructura como la mostrada en la Figura 78.

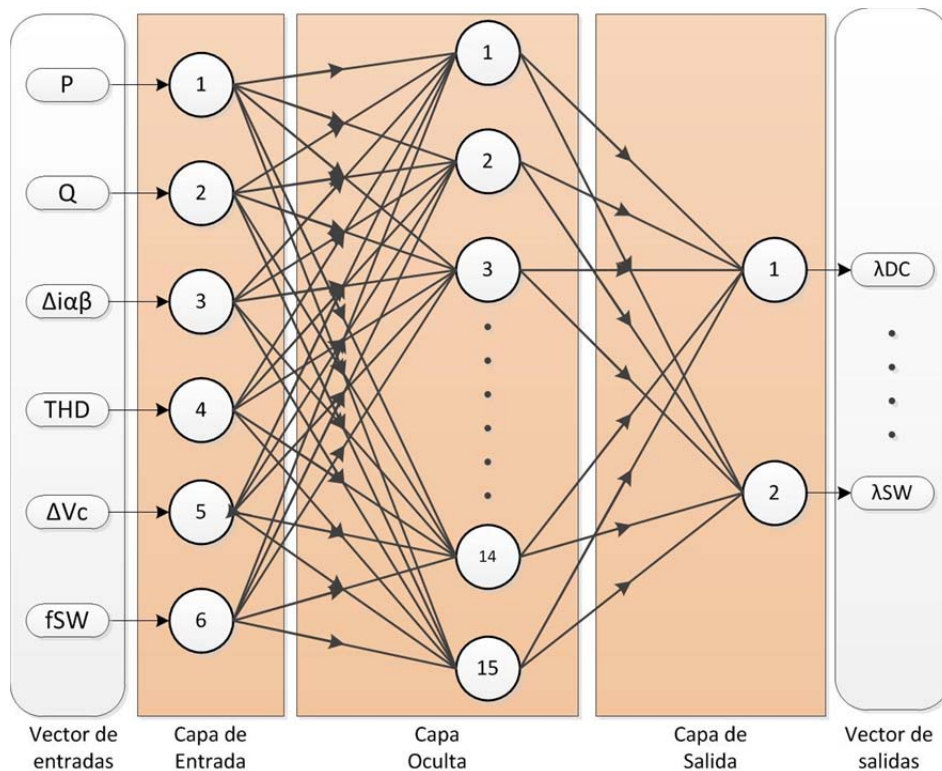


Figura 78. Diseño final de la FF-ANN que se implementará en el algoritmo A-MPC.

El resumen del proceso para determinar el diseño de la red neuronal es el siguiente:

1. **Obtención del número de entradas:** parámetro fijo, ya que son 6 las referencias que se tienen como entrada.
2. **Obtención del número de salidas y por tanto el de neuronas de la capa de salida:** parámetro fijo, ya que son 2 las salidas que se desean, en este caso los pesos de la función de coste.
3. **Número de neuronas de la capa oculta:** parámetro variable, obtenido mediante la experimentación observando la evolución del error que se comete en las salidas al ir aumentando el número de estas. La solución final se alcanza como un compromiso entre error de entrenamiento y los recursos que se necesitan para la implementación (cada neurona de la capa oculta de más, incrementa las operaciones que se deben hacer, y por tanto los recursos y el tiempo de cómputo).
4. **Tipo de función de transferencia de neuronas:** configuración variable, elegida mediante la experimentación. Para ello, se puede proceder a partir de la red neuronal con un número de neuronas óptimo en la capa oculta, y comprobar el error cometido con cada una de las posibles funciones de transferencia. En la Figura 79 se muestra esta comparación, usando una

función de transferencia tangente-sigmoial, o bien una lineal en la capa oculta. A la luz de los resultados experimentales, en esta tesis se optó finalmente por una función de transferencia Tangente-Sigmoial en las neuronas de la capa oculta, y por una función Lineal en las de la capa de salida.

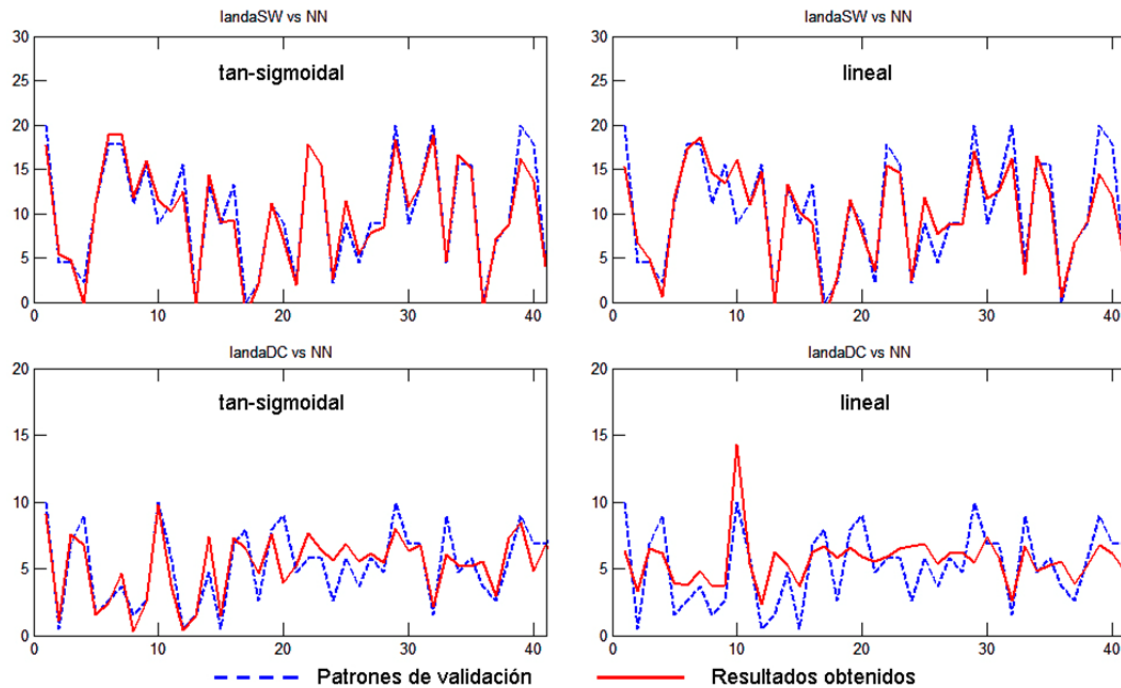


Figura 79. Comparación del resultado con patrones de validación sobre una FF-ANN usando funciones de transferencia Tangente-Sigmoial, o Lineal en la capa oculta de la red.

#### 4.2.2 Entrenamiento de la red neuronal

Utilizando la herramienta Neural Networks Toolbox de MATLAB, se ha realizado el entrenamiento con 2000 patrones de entrada diferentes, durante un máximo de **500 iteraciones** y un objetivo de error máximo del **3%**. El algoritmo de entrenamiento que se ha elegido es el de **Levenberg-Marquardt**, basado en la minimización del error cuadrático medio o **MSE** ya anteriormente comentado.

En los APÉNDICE finales se describen las funciones implicadas en el proceso del entrenamiento, así como los resultados que se obtuvieron durante el mismo para la FF-ANN definida.

El resultado del entrenamiento son los pesos y *bias* de las neuronas de la FF-ANN. Sin embargo, como al inicio del entrenamiento su valor es aleatorio, cada vez que se

realice el proceso de entrenamiento, este se comporta de una manera diferente, y por tanto puede llegar a un objetivo diferente de error. Para evitar el efecto de esta aleatoriedad, el entrenamiento de la FF-ANN se debe repetir varias veces, de tal manera que se seleccione finalmente aquel proceso de entrenamiento para el cuál se haya encontrado el menor error.

Al término del entrenamiento de la red neuronal, se tienen definidos los valores de los multiplicadores o pesos de cada entrada  $j$  para cada neurona  $i$ , de la capa oculta, que denominaremos  $\omega_{i-j}$ , y los de la capa de salida  $v_{i-j}$  con la misma notación; así como los valores de los offset o *bias*,  $b_i$  para la capa oculta y  $c_i$  para la capa de salida, los cuales se suman a las funciones de propagación en cada una de las neuronas. En la Tabla 25, Tabla 26 y Tabla 27 se muestran los valores de todos los pesos y constantes que resultan del entrenamiento de la red neuronal según los criterios anteriormente expuestos.

En la terminología habitual de las ANN y teniendo en cuenta el equivalente biológico, cuando un peso es positivo, se dice que esa entrada tiene una función excitadora sobre la neurona, ya que ayuda a incrementar el posible valor de la salida. Por otra parte, cuando el peso es negativo, se dice que tiene una función inhibidora al disminuir el valor de la salida.

Tabla 25. Factores multiplicativos o pesos de las neuronas de la capa oculta en la FF-ANN entrenada.

$w_{i-j}$						
Neurona	P	Q	$\Delta\alpha\beta$	THD	$\Delta Vc$	$f_{sw}$
1	0.19332747	0.49361006	2.03620667	-6.09252157	3.41192308	-1.12722723
2	0.00092614	0.00012059	0.22085024	-0.24788332	0.24011115	-0.16674654
3	-0.00229275	-0.00066056	3.32350981	-8.57303327	0.1739905	-0.01215997
4	1.50E-07	2.69E-06	-0.05431544	0.16342252	-0.11071251	-0.00158518
5	1.66E-06	-7.66E-06	0.01987172	0.29709146	0.00163638	-0.00236748
6	-1.04E-05	1.10E-05	0.06591384	4.56971135	0.37559577	0.00288951
7	-8.29E-06	4.33E-06	-0.10005611	0.41807104	0.59066855	-0.00064936
8	-1.05E-05	-1.09E-05	-0.02593214	1.94177216	0.16869249	-0.00199762
9	-7.60E-05	5.03E-06	3.35735302	29.1483444	0.00466021	-0.02137756

$w_{i-j}$						
Neurona	P	Q	$\Delta\alpha\beta$	THD	$\Delta V_c$	$f_{sw}$
10	-1.43E-07	-2.23E-06	-0.12462743	-0.15387614	0.00199591	-0.00021215
11	-1.45E-05	2.68E-06	0.01344859	1.43210173	0.33269386	-5.37E-05
12	-1.93E-05	4.85E-05	0.22405372	-1.81306799	-0.35676784	0.00192417
13	-0.00056834	-0.00016389	-5.28795045	-24.8189234	0.04989409	0.11723334
14	2.10E-05	1.28E-05	-0.09229763	-5.64822146	-0.07598684	-0.00401715
15	1.89E-05	2.25E-05	0.2390375	-2.61526501	-0.06696305	-0.00110073

Tabla 26. Factores multiplicativos o pesos de las neuronas de la capa de salida en la FF-ANN entrenada.

$v_{i-j}$								
Neurona	1	2	3	4	5	6	7	8
1 ( $\lambda_{DC}$ )	0.094	-3.316	0.0631	4.327	-0.3227	1.393	-3.88	1.645
2 ( $\lambda_{SW}$ )	0.1883	4.0562	-0.1286	-3.172	9.439	4.305	1.793	7.081
Neurona	9	10	11	12	13	14	15	
1 ( $\lambda_{DC}$ )	0.1692	-2.625	-1.735	-0.557	0.1576	-0.6618	0.859	
2 ( $\lambda_{SW}$ )	0.2783	-10.26	-4.332	0.657	-0.118	0.0382	0.836	

Tabla 27. *Bias* de las neuronas de la capa oculta y la capa de salida en la red FF-ANN diseñada.

$b_i$	$c_i$
12.99	-3.947
-3.876	2.2586
14.621	
3.082	
2.504	
-7.015	
1.706	
3.931	
-43.307	
2.077	
-1.413	
-2.403	
6.855	

9.962	
-1.627	

Otro detalle importante a destacar de los pesos mostrados en la Tabla 25, es que los factores multiplicativos para las entradas correspondientes a la referencia  $P$ , y la referencia  $Q$  son mucho menores que los de las otras entradas. Este hecho se debe principalmente a que tanto  $P$  como  $Q$  tienen valores muy elevados, al tratarse de configuraciones de potencia, del orden de miles de vatios. Como se observa, el propio entrenamiento de la red neuronal, tiene la capacidad de adaptarse a la dimensión de las entradas, modulando los valores de los factores multiplicativos para que las salidas resultantes sean del mismo orden. Así, valores de entrada como por ejemplo  $P=100.000W$ , tienen igual relevancia a priori que por ejemplo  $THD=0.15$  (15%), que como se puede apreciar tiene, en general, factores multiplicativos más altos.

#### 4.2.3 Simulación del funcionamiento de la red neuronal

Para aplicar la red FF-ANN y simular su comportamiento, se utilizan las funcionalidades que incorpora MATLAB explicadas en los APÉNDICE finales.

La Figura 80 muestra una comparativa entre las salidas reales de los 100 primeros patrones de validación, con las obtenidas a partir de la FF-ANN entrenada, observándose que, aunque se modela el comportamiento del sistema con algunos errores, estos cumplen con la especificación de que sea menor que el 3%, que fue el ratio definido para el entrenador de la FF-ANN, y la red neuronal sigue adecuadamente dichos patrones de validación. En la Figura 81, se aprecia que la media y varianza del error cometido por la red neuronal entrenada, son menores que los obtenidos cuando se emplean otros métodos descritos con anterioridad como los mostrados en el punto 3.4.




Figura 80. Muestra de los 100 primeros resultados con patrones de validación aplicados a la FF-ANN diseñada.




Figura 81. Error medio cometido en las salidas de la red neuronal.

### 4.3 Conclusiones

El objetivo principal de este capítulo, era el presentar una propuesta concreta para la función de optimización del algoritmo A-MPC, resultando las siguientes conclusiones:

- Se ha definido la propuesta de optimización para el algoritmo A-MPC, basada en la utilización de una red neuronal artificial de propagación hacia adelante (FF-ANN) con arquitectura de Perceptrón Multicapa, con una capa de entrada, una capa oculta, y una capa de salida sin utilizar pre-procesamiento.
- La FF-ANN se ha definido con 6 entradas, asociadas a las dos consignas de potencia  $P^*$  y  $Q^*$ , junto con los cuatro índices de calidad del sistema definidos en el CAPÍTULO 3, a saber:  $\Delta i\alpha\beta^*$ ,  $THD^*$ ,  $\Delta Vc^*$  y  $f_{sw}^*$ . La salida de la FF-ANN por su parte, son los dos factores de peso  $\lambda_{DC}$  y  $\lambda_{SW}$  de la función de coste definida para el algoritmo MPC descrito en el CAPÍTULO 2.
- Mediante un proceso puramente empírico, se ha encontrado el número de neuronas óptimas en la capa oculta, para conseguir los mejores resultados de aproximación, fijándose este número en 15 neuronas. Del mismo modo, se ha demostrado cómo se consiguen los mejores resultados utilizando una función de transferencia tangente-sigmoidal en la capa oculta, y una lineal en la de salida.
- Se ha demostrado que utilizando un algoritmo de entrenamiento de *backpropagation* basado en la minimización del error cuadrático medio (MSE), como el Levenberg-Marquardt (LMA), se consiguen errores por debajo del 3% en la aproximación de la función que modela el comportamiento del inversor.
- Finalmente, y tras realizar el entrenamiento de la red, se han obtenido los valores de los factores multiplicativos  $\omega_i$  y los offsets  $b_i$ , con los que ha quedado definido el diseño final de la red FF-ANN.



# CAPÍTULO 5. RESULTADOS EXPERIMENTALES

## 5.1 Aplicación del Control Predictivo Adaptativo

En los capítulos anteriores se ha propuesto un algoritmo basado en ANN, junto con una metodología para conseguir un controlador predictivo adaptativo, capaz de ajustar los pesos de la función de coste de optimización siempre que se produzca un cambio de consignas de potencia activa  $P^*$  o reactiva  $Q^*$ , o de los objetivos de control, a saber: desviación media de corriente o tracking  $\Delta i_{\alpha\beta}$ , distorsión armónica  $THD$ , desbalanceo del bus-DC  $\Delta V_c$  y frecuencia de conmutación de los IGBT  $f_{sw}$ .

En este apartado se mostrarán las pruebas experimentales que se han llevado a cabo para evaluar las prestaciones de la propuesta de control realizada en esta tesis, comparando los resultados obtenidos con los resultados de los controladores predictivos no adaptativos.

Para ello, se considerarán diferentes escenarios relativos a cambios en las referencias de potencia del convertidor, evaluando, en primera instancia los controladores no adaptativos y posteriormente el controlador propuesto en esta tesis. Se pretende demostrar que cuando los cambios en las referencias provocan deterioro en los índices de calidad, el algoritmo A-MPC es capaz de corregir el comportamiento para que no se produzcan tales efectos.

## 5.2 Resultados de la implementación de la FF-ANN

Una vez se ha entrenado la red neuronal para que modele el comportamiento del sistema seleccionado (función de adaptabilidad), y ayude al ajuste dinámico de la función de coste ante cambios de las consignas u objetivos de control, se aborda en este apartado la implementación hardware de la misma. Como el entrenamiento se ha llevado a cabo *offline*, una vez que se tengan los pesos y parámetros de la red, estos datos serán fijos y son los que se deberán implementar. En esta tesis no se ha contemplado la opción de que los pesos de la ANN puedan cambiarse de forma online, es decir, en el transcurso del funcionamiento del controlador A-MPC aunque se ha identificado este punto como una mejora incluida en trabajos futuros. Por tanto, se

asume que la red neuronal está adaptada a un caso concreto de funcionamiento para un sistema con una configuración determinada: tensión del Bus-DC, tensión de red, filtro RL, período de muestreo, etcétera.

A continuación, siendo los pesos y *bias* de las neuronas valores conocidos, la FF-ANN se implementa en el propio controlador como un módulo independiente, en el que se calculan y ajustan los parámetros de peso  $\lambda_{DC}$  y  $\lambda_{SW}$  de la función de coste cada vez que haya un cambio en las consignas.

Con la inclusión de esta red neuronal, se pretende que ante un cambio en una de las consignas, por ejemplo al cambiar la potencia activa P, el propio controlador sea capaz de adaptar los pesos de su función de coste para intentar mantener los índices de calidad en los mismos valores antes de producirse el cambio. En la siguiente sección de este capítulo, se mostrarán algunos casos de estudio que permiten apreciar la mejora que ofrece esta solución frente a aquellos que no ajustan dinámicamente los pesos de la función de coste.

En este apartado, se analizará la implementación del bloque de adaptación que incluye la red neuronal, en el caso habitual de emplear una FPGA.

### 5.2.1 Diseño del bloque ANN

La FF-ANN se ha entrenado, validado y testeado a partir de los patrones almacenados en la base de datos. La implementación que se realice debe proporcionar resultados coincidentes con los resultados obtenidos para la misma red usando MATLAB, salvo quizás pequeños errores asociados a la propia implementación, como puedan ser errores de cuantificación al pasar a punto fijo o errores de aproximación al implementar funciones no lineales.

El diseño de la FF-ANN, se realiza para una plataforma de desarrollo basada en la familia de FPGA de Xilinx **Zynq-7000 ZC702**, la cual incorpora la FPGA XC7Z020 CLG484-1. Esta FPGA está basada en un modelo dual que incluye un sistema de procesamiento software (PS - Processing System) con 2 microcontroladores ARM Cortex A9, y por otro lado una parte lógica programable (PL – Programmable Logic) para implementación hardware en la que se implementará la FF-ANN. En el bloque PL existen hasta 220 bloques de proceso *DSP48E1* que funcionan hasta 250MHz y pueden realizar multiplicaciones de datos de **18 x 25 bits**, y son los usados para realizar las operaciones MAC (73). Así mismo, tiene más de 85K celdas lógicas y modelo de implementación se ha diseñado para trabajar a una frecuencia de reloj de

**50MHz** (42) (23). Para realizar el diseño, se ha optado por usar la herramienta *Xilinx System Generator*, (en adelante, XSG) para la utilización de la implementación realizada del algoritmo MPC y la herramienta HDL Coder de MATLAB para la generación automática de código VHDL a partir de un modelo de Simulink. Estas herramientas permiten realizar diseños de una manera rápida y sencilla, llevar a cabo simulaciones sobre el hardware y generar código VHDL automáticamente (74) (75). Además, permite integrar el diseño en paralelo con el de MATLAB, a fin de comparar si los resultados son equivalentes.

En una implementación en FPGA, se deben de tener en cuenta las siguientes consideraciones o reglas de diseño recomendadas (76), con objeto de minimizar el tiempo de desarrollo y facilitar la detección y corrección:

- Todos los valores del modelo, debe representarse en formato de punto fijo con una longitud máxima de 128 bits, sin que ello afecte al comportamiento del sistema. Por tanto, los valores reales (*double*) pueden usarse para simulación, pero no serán sintetizables.
- Se pueden implementar divisiones entre números enteros en punto fijo, aunque son operaciones que deben evitarse por el elevado tiempo de cómputo.
- En operaciones de múltiples condiciones (*switch case*), se deben contemplar todas las posibilidades.
- Instrucciones o bloques de ruptura y bucles de espera no están permitidos.
- Los bucles finitos (*for*) están permitidos siempre que las expresiones y condiciones solo tengan escalares.
- No se pueden usar matrices como entradas de los bloques.
- No está permitido usar señales o datos de tamaño variable.
- Serializar las entradas y salidas: trabajar siempre con tramas en vez de entradas y salidas en paralelo.
- Usar operaciones MAC siempre que sea posible.

Con todas estas consideraciones, para realizar el diseño de la FF-ANN, se comienza por definir sus características fundamentales, que en este caso son las mismas que las utilizadas al diseñarlas con MATLAB:

- Tipo de red neuronal: Perceptrón Multicapa.
- N° de entradas: 6, correspondientes a las referencias del sistema.
- N° de neuronal en capa oculta: 15.

- Tipo de función de transferencia en neuronas de capa oculta: Tang-Sigmoidal. Esta función no es lineal, con lo que su implementación se hace mediante la aplicación de una tabla de valores precalculados.
- N° de neuronas en capa de salida: 2, correspondientes a los dos parámetros de pesos.
- Tipo de función de transferencia en neuronas de capa de salida: Lineal.

A la hora de implementar la red neuronal, hay que tener en cuenta primeramente el número de operaciones que se deben realizar según la configuración elegida. Según lo visto en el apartado 4.2.1, en relación a la estructura básica de una neurona y el tipo de diseño elegido, se pueden considerar los modelos computacionales, o grafos de operaciones, de las neuronas de la capa oculta y de salida, como los que se muestran en la Figura 82 y la Figura 83, en las que además se ha realizado una planificación de operaciones atendiendo a las dependencias de datos, para que el tiempo de ejecución sea el menor posible.

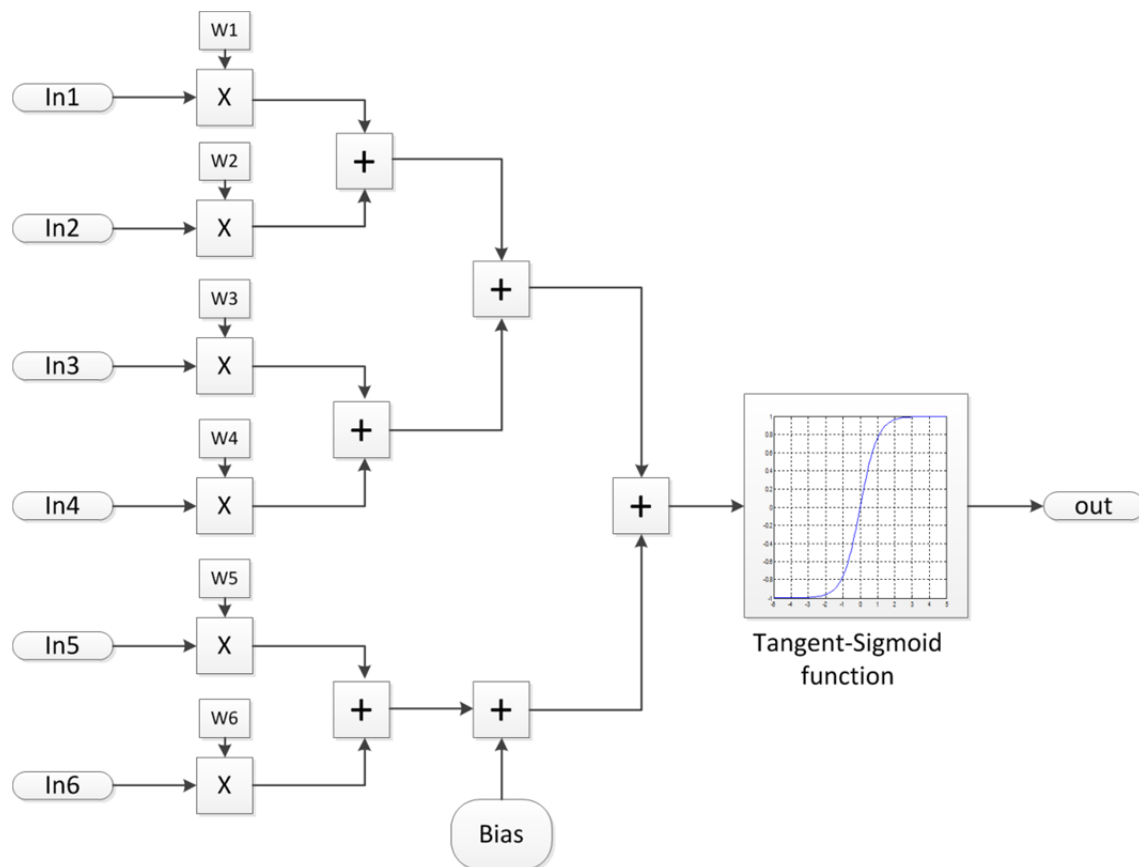


Figura 82. Estructura computacional de una neurona de la capa oculta para la estructura de red neuronal propuesta.

Observando la Figura 82, se llega a la conclusión de que por cada neurona de la capa oculta se deben realizar las siguientes operaciones MAC:

- 6 Multiplicaciones de las entradas por sus pesos.
- 6 Operaciones de suma entre todos los términos y el offset o *bias* de la neurona.

Por su parte, la implementación de la función de transferencia Tangente-sigmoidal debe considerarse de manera especial, al tratarse de una función no lineal.

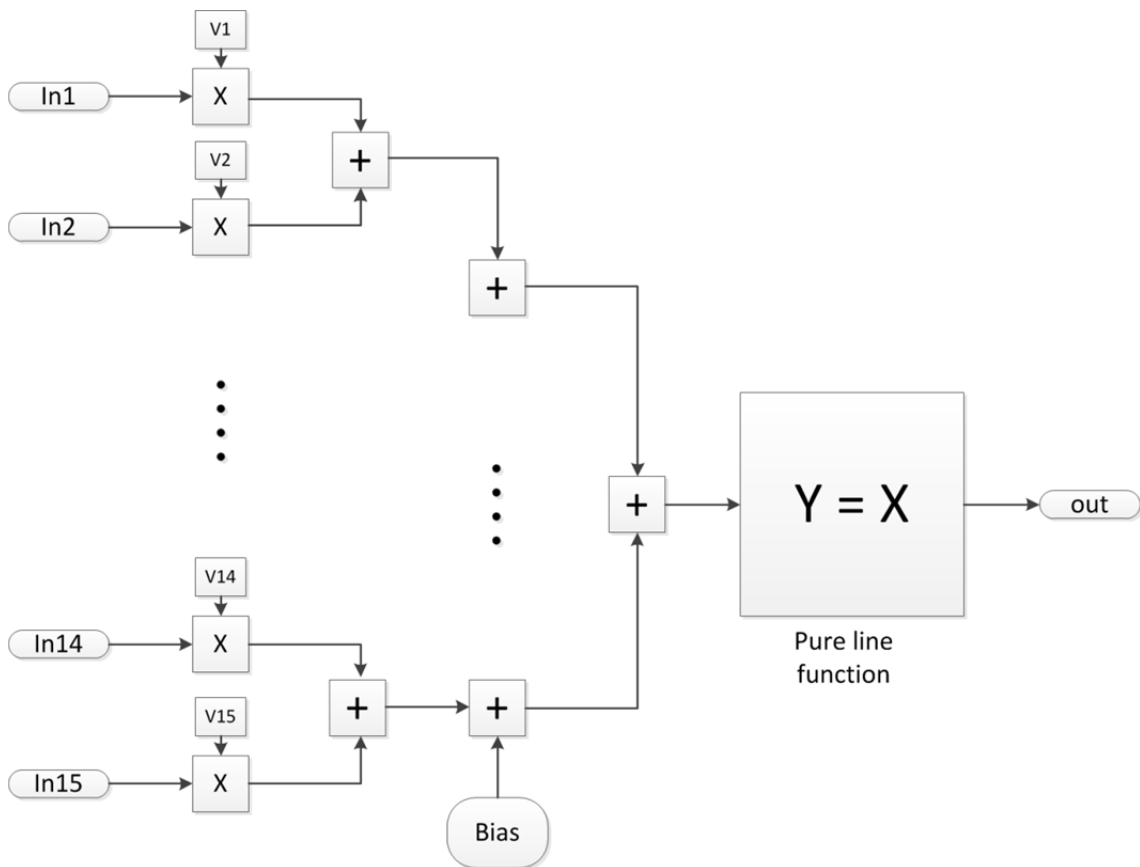


Figura 83. Estructura computacional de una neurona de la capa de salida para la estructura de red neuronal propuesta.

Por otro lado, la Figura 83 muestra el grafo de operaciones para una neurona de la capa de salida, donde se ve que si cada una tiene 15 entradas (provenientes de cada una de las neuronas de la capa oculta), se necesitarán las siguientes operaciones MAC:

- 15 Multiplicaciones de las entradas por sus pesos

- 15 Operaciones de suma entre todos los términos y el offset o *bias* de la neurona.

A diferencia de las neuronas de la capa oculta, la función de transferencia para las neuronas de la capa de salida es lineal, descrita por:

$$ft(x) = x \quad [64]$$

### 5.2.2 Implementación de la función Tangente-Sigmoidal

La función Tangente-sigmoidal, está descrita por la expresión no lineal:

$$ft(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad [65]$$

La curva característica de esta función se muestra en la gráfica de la Figura 84.




Figura 84. Función de transferencia tangente-sigmoidal.

Las alternativas para implementar esta función son básicamente dos, a saber, mediante una tabla de valores con los suficientes puntos como para que el error cometido sea pequeño o un bloque proporcionado por un entorno de desarrollo. Sin

embargo, estos no suelen ser compatibles con la generación automática de código VHDL de XSG/HDL Coder. Además, normalmente pueden llevar varios ciclos de ejecución de reloj obtener los resultados. Por este motivo, resulta muy recomendable implementar directamente las funciones de este tipo mediante una tabla de valores.

En este caso, la función Tangente-sigmoidal se ha implementado mediante una tabla de valores. Viendo la Figura 84, se observa como una cuantificación uniforme sobre todo el dominio de dicha función para obtener una tabla de valores, puede no resultar muy efectiva, debido a que en la zona próxima al origen, la función tiene gran pendiente y los escalones de cuantificación serían mayores (provocando mayores errores también), que los de los extremos. Para minimizar esto, se ha realizado una cuantificación de la función dividiéndola en dos zonas diferentes: la zona central o en torno al origen con una mayor resolución, y los extremos de la función con menor resolución en la cuantificación. Por otro lado, la Tangente-sigmoidal presenta simetría impar, por lo que bastaría con tener una tabla de valores sólo de una de las mitades (por ejemplo el semieje positivo), y propagar el signo de a ordenada en el origen al dato de salida. Así pues, los valores de las tablas se obtienen a partir del valor absoluto de la variable de entrada. De igual forma, viendo la tendencia de la función, se realiza una saturación de la variable de entrada siempre que ésta sea superior a 5. Para que cualquier valor de entrada esté entre estos límites, se incluye un bloque de saturación por encima y por debajo.

Para este caso concreto, la Tangente-sigmoidal se ha implementado con una tabla de valores de 150 puntos para valores pertenecientes al intervalo central  $[0, 2]$ , y otros 150 puntos para valores comprendidos en el intervalo  $(2, 5]$ . Como las tablas van a ser de 150 posiciones (empezando en la posición 0), se debe realizar una conversión del valor de entrada a la posición de la tabla, esto es: de  $[0,2]$  a  $[0,149]$  para valores centrales, o bien de  $(2,5]$  a  $[0-149]$  para los valores de la zona externa, de tal manera que con la conversión se obtenga la posición o dirección de la tabla donde se guarda el resultado para el valor original. En la siguiente tabla, se muestran una parte de los valores que contienen las tablas utilizadas para la implementación.

Tabla 28. Muestra de valores contenidos en las tablas incluidas para modelar la función no lineal Tangente-sigmoidal.

Dirección	Tabla Central		Tabla Exterior	
	X	Y	X	Y
0	0,0000	0,0000	2,0200	0,9654
1	0,0134	0,0134	2,0400	0,9667
2	0,0268	0,0268	2,0600	0,9680

Dirección	Tabla Central		Tabla Exterior	
3	0,0403	0,0402	2,0800	0,9693
4	0,0537	0,0536	2,1000	0,9705
5	0,0671	0,0670	2,1200	0,9716
6	0,0805	0,0804	2,1400	0,9727
7	0,0940	0,0937	2,1600	0,9737
8	0,1074	0,1070	2,1800	0,9748
9	0,1208	0,1202	2,2000	0,9757
10	0,1342	0,1334	2,2200	0,9767
11	0,1477	0,1466	2,2400	0,9776
12	0,1611	0,1597	2,2600	0,9785
13	0,1745	0,1727	2,2800	0,9793
.	.	.	.	.
.	.	.	.	.
.	.	.	.	.
144	1,9329	0,9590	4,9000	0,9999
145	1,9463	0,9600	4,9200	0,9999
146	1,9597	0,9611	4,9400	0,9999
147	1,9732	0,9621	4,9600	0,9999
148	1,9866	0,9631	4,9800	0,9999
149	2,0000	0,9640	5,0000	0,9999

Con esta disposición en las tablas de valores, se obtiene un patrón de error de cuantificación como el mostrado en la Figura 85, en la que se observa que el máximo error está justo en el origen y resulta en torno a  $7e-3$ . Además se observa como para las zonas exteriores de la función (valores por encima de  $\pm 2$ ), el error es aún más bajo en torno a  $2e-3$ .

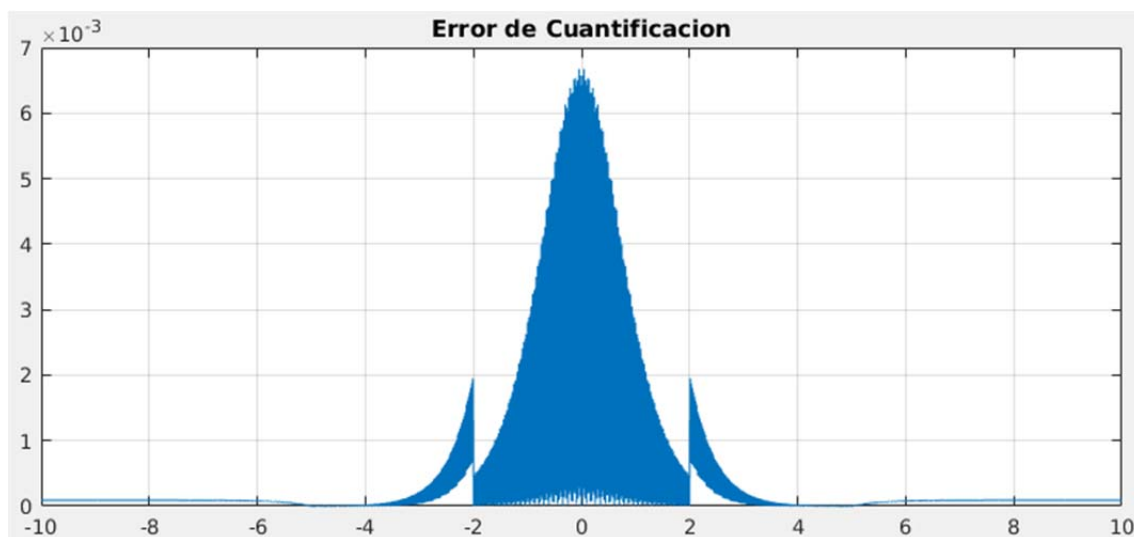


Figura 85. Error de cuantificación en la implementación de la función Tangente-sigmoïdal mediante tablas de valores precalculados.



De esta manera, la realización de la función no lineal, se traduce en realizar una operación de lectura sobre una memoria donde se guardan los resultados. La implementación final en XSG de esta función, se muestra en la siguiente figura. En ella se observa además como la latencia del modelo es de 2 ciclos de reloj.

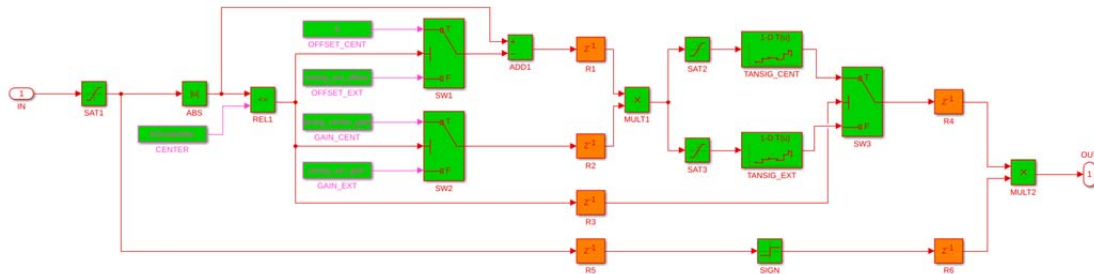


Figura 86. Modelo de implementación en Simulink de la función Tangente-sigmoidal.

### 5.2.3 Implementación de una neurona de la capa oculta

Para implementar una neurona de la capa oculta, se ha hecho uso de la función Tangente-sigmoidal descrita anteriormente, incluyéndose los 6 multiplicadores y 6 sumadores descritos en el diseño de la ANN. La Figura 87 muestra una imagen genérica de cómo se implementaría la neurona con bloques de HDL Coder en Simulink. Viendo la imagen, se observa además como la latencia del modelo es de 4 ciclos de reloj, a los que hay que añadir los 2 ciclos de ejecución de la función Tangente-sigmoidal, resultando un total de 6 ciclos de reloj para la ejecución de una neurona de la capa oculta.

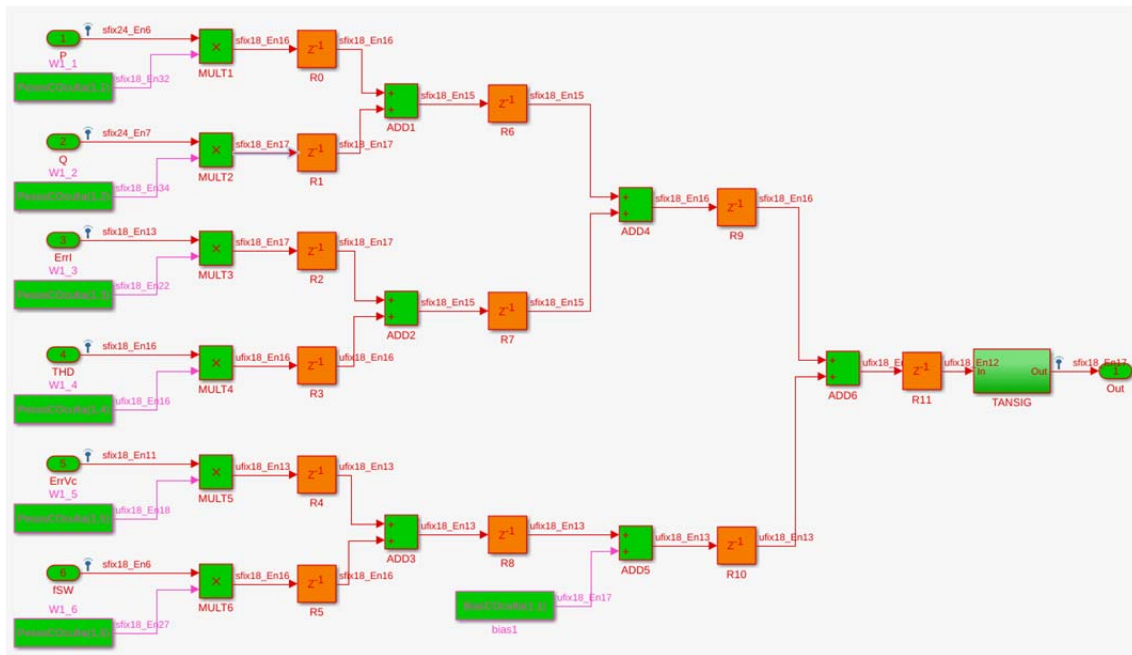


Figura 87. Modelo de implementación en Simulink-HDL Coder de una neurona de la capa oculta.

## 5.2.4 Implementación de una neurona de la capa de salida

En la Figura 88 se observa el diseño en Simulink-HDLCoder de una neurona de la capa de salida, incluyendo los 15 multiplicadores y los 15 sumadores. Al tener una función de transferencia lineal, la salida de la función de propagación es directamente la salida de la neurona. La latencia para las neuronas de la capa de salida, es en este caso de 4 ciclos de reloj, debido a que no tiene que ejecutarse la función Tangente-sigmoidal.

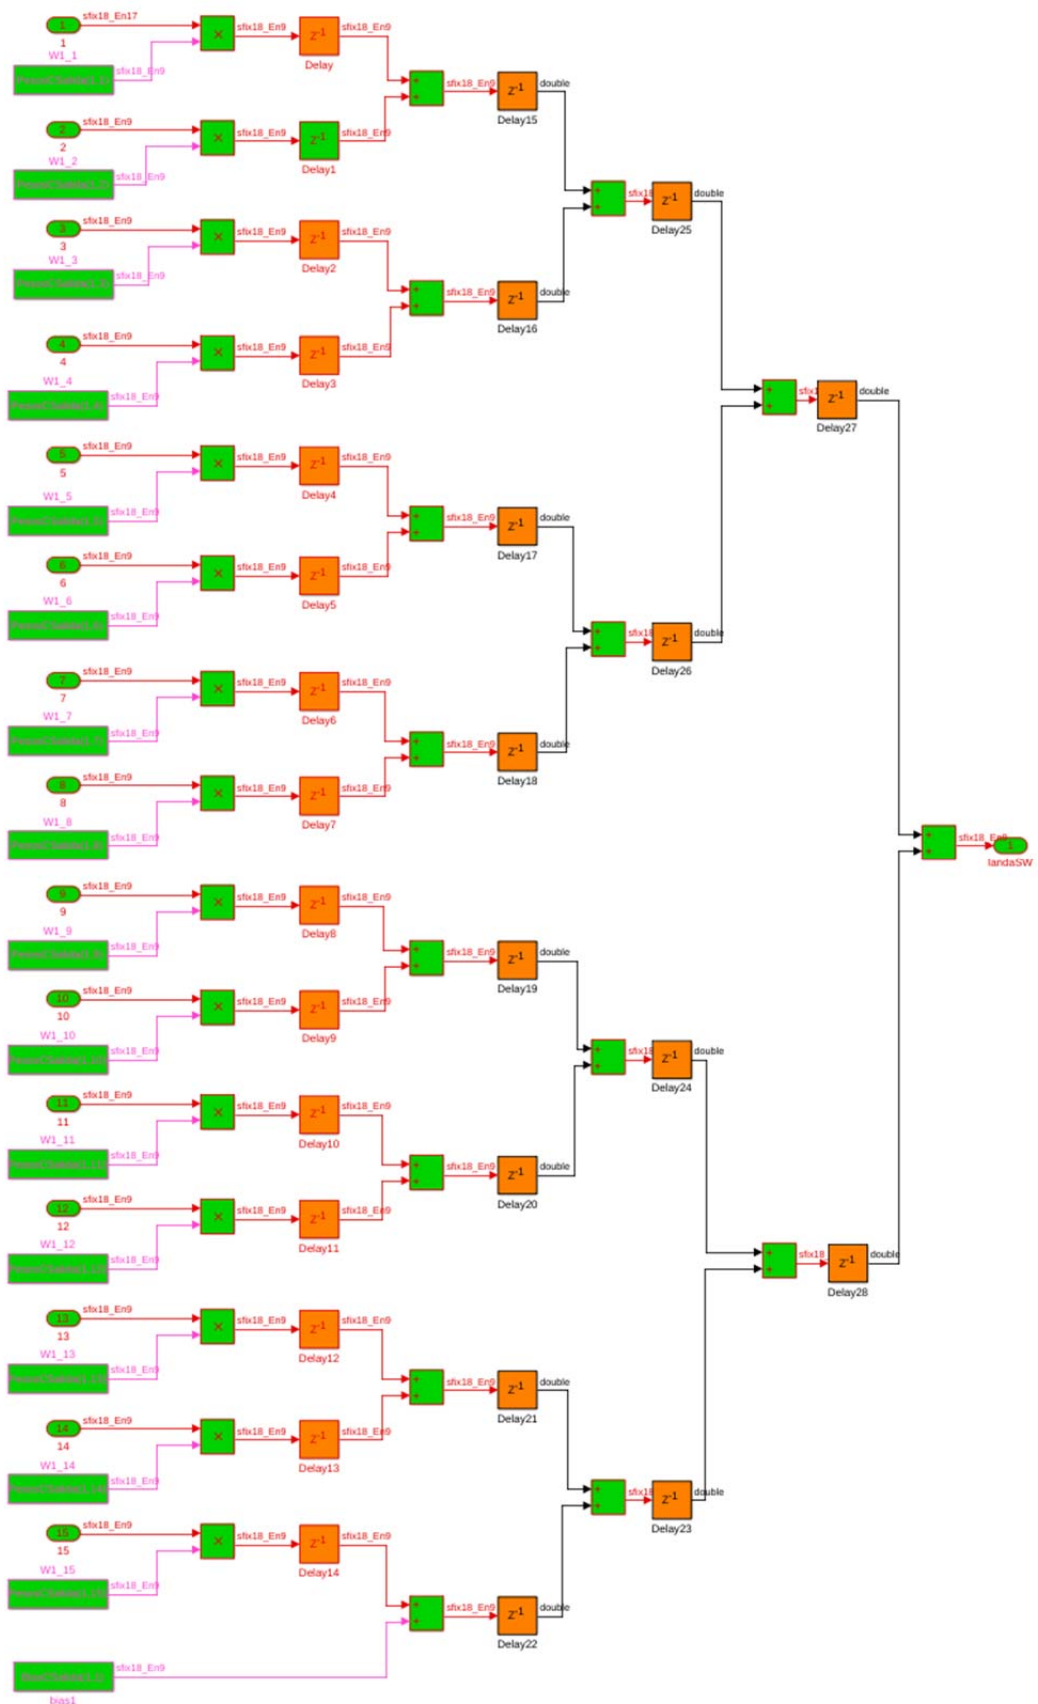


Figura 88. Implementación en Simulink de una neurona de la capa de salida.

## 5.3 Resultado de la implementación de la FF-ANN

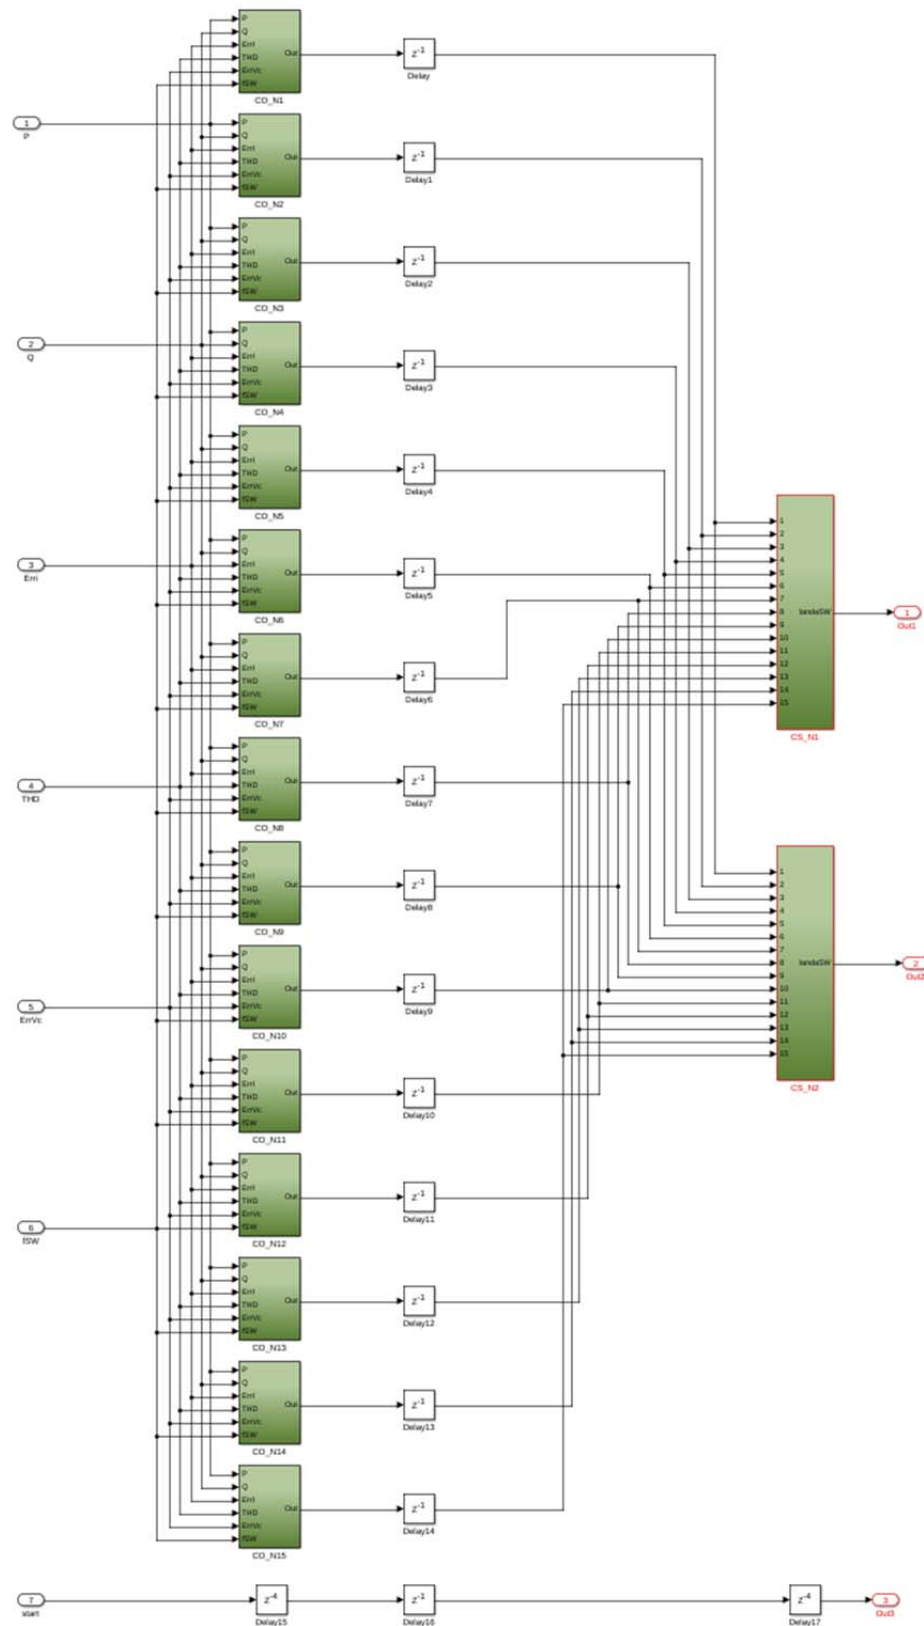


Figura 89. Implementación en Simulink-HDLCoder de la red FF-ANN completa.

La Figura 89 muestra el esquema del diseño de toda la FF-ANN, en la, además de los aspectos ya comentados, se deben incluir también registros entre la salida de la capa oculta y la entrada de la capa de salida, añadiendo un ciclo más de latencia al proceso. De este modo, la latencia total de la FF-ANN resulta ser de 11 ciclos de reloj: 6 ciclos de la capa oculta, 1 ciclo entre capas y 4 ciclos de la capa de salida. Para una frecuencia de 50 MHz, esto supone un tiempo de proceso de **220ns**.

### 5.3.1 Comparativa entre simulación e implementación

Al trabajar con valores en punto fijo, es inevitable una pérdida de resolución de todas las señales que intervienen en el modelo. Además, la implementación de funciones no lineales mediante el uso de tablas de valores, añade un error de cuantificación. En esta tesis, se ha implementado la red neuronal trabajando con un ancho de datos de 18 bits, y la función Tangente-Sigmoidal se ha implementado con 300 puntos. El ancho de datos o longitud de palabra de 18 bits, resulta óptimo debido a que en la FPGA utilizada, las operaciones de suma-resta y multiplicaciones se llevan a cabo en unidades digitales de proceso dedicadas (DSP48) que trabajan con este tamaño de datos. Como todas las operaciones llevadas a cabo por el algoritmo A-MPC utilizan finalmente estos bloques, conviene que los datos no superen este tamaño para impedir que se realicen varios ciclos para un único dato, y así aumentar la latencia de las operaciones y por tanto el tiempo de respuesta. Por otro lado, si se reduce este tamaño a menos de 18 bits, se perdería resolución al utilizar formatos en punto fijo, aumentándose el error de cuantificación.

En la Figura 90 se muestran los primeros 200 patrones de un estudio del error de cuantificación realizado con 800 patrones de resultados, comparando los resultados obtenidos usando la FF-ANN con MATLAB y formato *double* de 64 bits, respecto al modelo de implementación en Simulink con 18 bits de ancho de palabra en punto fijo.





Figura 90. Muestra de una comparativa de resultados obtenidos tras aplicar patrones de validación a la FF-ANN desde MATLAB, y desde el modelo implementado con Simulink.

El error cuadrático medio de cuantificación para el total de 800 patrones cometido en la implementación de la FF-ANN resultó ser de  $7,7814e-6$  para la obtención del parámetro  $\lambda_{SW}$ , y de 0.0072 para  $\lambda_{DC}$ .

### 5.3.2 Recursos consumidos y camino crítico

Con todos los elementos de la FF-ANN ya diseñados, se ha utilizado la generación automática de código VHDL desde Simulink para obtener la implementación hardware del modelo. A continuación se muestra el porcentaje de utilización de los recursos de la FPGA que incorpora la placa de desarrollo ZC702, que se necesitan para la implementación de la FF-ANN para aplicar el algoritmo A-MPC. En la Tabla 29 aparecen además de los recursos más importantes ( LUTs, “DSP Slices” o DSP48 y Flip-flops), las entradas y salidas o “IO” las cuales se muestran como el recurso más utilizado. Sin embargo, este dato no ha de tenerse en cuenta, pues resulta de la sintetización en lógica programable directa de una entidad individual VHDL sin tener en cuenta toda la infraestructura donde se enmarca. Desde la herramienta Vivado de Xilinx, las entidades VHDL se comunican mediante buses AXI de comunicación, por lo que los puertos de entrada y salida de la FF-ANN son conectados a estos buses y no a entradas y salidas propias de la FPGA.

Tabla 29. Recursos consumidos en la implementación VHDL de la FF-ANN en la placa ZC702.



Por otro lado, el análisis temporal para saber la frecuencia máxima de trabajo del bloque, se realizó primeramente desde el entorno de Simulink para comprobar la máxima frecuencia a la que puede trabajar el modelo de implementación de la FF-ANN. En este caso, los resultados estimados aportados por Simulink, indicando el camino crítico dentro del modelo, resultó:

Tabla 30. Análisis de tiempos realizados desde Simulink después de la generación de código VHDL de la FF-ANN.

### Critical Path Details

Id	Propagation (ns)	Delay (ns)	Block Path
1	0.2980	0.2980	<a href="#">Delay</a>
2	1.4960	1.1980	<a href="#">Add1</a>
3	2.6940	1.1980	<a href="#">Add4</a>
4	3.8920	1.1980	<a href="#">Add6</a>
5	6.0350	2.1430	<a href="#">Saturation</a>
6	10.0390	4.0040	<a href="#">Product1</a>
7	10.0390	0.0000	<a href="#">Add1</a>
8	10.0390	0.0000	<a href="#">Conversion tipo 16 bits</a>
9	10.0390	0.0000	<a href="#">TansigTable</a>
10	10.0690	0.0300	<a href="#">Delay</a>

En la anterior tabla, se muestran los elementos del modelo que después de ser trasladados a VHDL y ser analizados, tuvieron mayores tiempos de propagación y retardos. El camino crítico más elevado resultó ser de 10.069ns, correspondiente a una frecuencia máxima de trabajo permitida de **99.31 MHz**. Teniendo en cuenta que la frecuencia de trabajo del algoritmo de Control Predictivo en la FPGA se fijó en 50 MHz,

o 20 ns de ciclo de reloj, se tienen las suficientes garantías para asegurar que la implementación cumple las restricciones temporales de velocidad de la FPGA.

Como se aprecia, los registros de retardo  $Z^{-1}$  colocados entre cadenas de procesos, han permitido que los tiempos de propagación de realización de las sumas (“*Delay*” de la última fila), y las multiplicaciones (por ejemplo “*Product1*”) sean parecidos, en torno a los 10ns. De esta manera, se ha equilibrado el tiempo de propagación entre las etapas de la segmentación realizada.

Para realizar una comprobación más rigurosa de la frecuencia de trabajo del modelo de implementación, tras obtener el código VHDL de la FF-ANN, éste se sintetizó e implementó en la FPGA desde el entorno de Vivado de Xilinx, configurando un reloj de trabajo de 50 MHz.

Tabla 31. Reportes de análisis temporales del bloque implementado de la FF-ANN desde el entorno de Vivado, sobre la placa de evaluación ZC702.

Timing	
Worst Negative Slack (WNS):	0.206 ns
Total Negative Slack (TNS):	0 ns
Number of Failing Endpoints:	0
Total Number of Endpoints:	1027
<a href="#">Implemented Timing Report</a>	
Setup Hold Pulse Width	
Timing	
Worst Hold Slack (WHS):	0.248 ns
Total Hold Slack (THS):	0 ns
Number of Failing Endpoints:	0
Total Number of Endpoints:	1027
<a href="#">Implemented Timing Report</a>	
Setup Hold Pulse Width	
Timing	
Worst Pulse Width Slack (WPWS):	9.5 ns
Total Pulse Width Negative Slack (TPWS):	0 ns
Number of Failing Endpoints:	0
Total Number of Endpoints:	475
<a href="#">Implemented Timing Report</a>	
Setup Hold Pulse Width	

En la tabla anterior, se muestran los parámetros conocidos como “*slacks*”, los cuales se definen como la diferencia entre el tiempo máximo disponible entre dos operaciones y su conexión (en este caso 20 ns al ser el reloj de 50 MHz), y el tiempo que realmente necesita para ejecutarse. *Slacks* positivos como en este caso, indican que la entidad se puede ejecutar sin problemas para la frecuencia fijada.



Como se deduce del número de operaciones anteriores, la implementación de la red neuronal juega un papel importante, debiéndose realizar a conciencia, y por tanto está condicionada claramente por los recursos disponibles, más que por el tiempo de ejecución de todas las operaciones. Concretamente, y por ser uno de los recursos más limitados, los multiplicadores, sintetizados usando los bloques de proceso DSP48E1, son los elementos que más críticos.

## 5.4 Configuración experimental

Para llevar a cabo los experimentos expuestos a continuación, se ha hecho uso de una plataforma compuesta por los siguientes elementos y características, cuyo elemento principal es el convertidor 3L-NPC descrito en trabajos anteriores como (38):

- Convertidor 3L-NPC: Formado por un convertidor trifásico de tipo back-to back de 3 niveles. Está compuesto por un bloque rectificador y otro inversor, ambos con una potencia de hasta 150kVA, capaces de aportar una corriente nominal de hasta 312.5A. Para las pruebas, se ha tenido en cuenta solamente el bloque inversor, considerando que el rectificador es capaz de aportar la tensión continua del Bus-DC. Cada rama del inversor está compuesta por dos módulos FD300R12KE3 y dos DF300R12KE3 (6 módulos de cada tipo para el inversor) con tensiones nominales de 1000V. Estos elementos poseen una resistencia térmica de 0.02°K/W pudiendo aguantar hasta 125°C, y según estudios realizados de temperatura, pueden tener una frecuencia de conmutación de hasta 2.5kHz. La tensión máxima del Bus-DC está fijada en 1200V, por lo que cada condensador debe soportar hasta 600V. Por ello, la tensión nominal de los condensadores utilizados es de 700V y de valores 2250μF (formados por 3 condensadores electrolíticos en paralelo de 750μF cada uno).
- Filtro de red: compuesto por una inductancia de 0.75mH, de corriente nominal 195 Arms y máxima de 275A. Todo el sistema electrónico de potencia formado por el convertidor, los sensores, el filtro de red, los drivers de los IGBTs y demás elementos, se muestran en la Figura 91.
- FPGA de desarrollo Xilinx Zynq ZC702 junto al Sistema Electrónico de Control: La tarjeta de comunicaciones hace de interfaz entre las señales ópticas de control de los IGBT, los relés de control de los interruptores del convertidor, y la

tarjeta FPGA donde se ha implementado el controlador A-MPC del inversor, así como el controlador existente del bloque rectificador utilizando un microcontrolador o DSP TMS320C6713. El sistema de electrónica de control, se muestra en la Figura 92, y el de interfaz en la Figura 93.

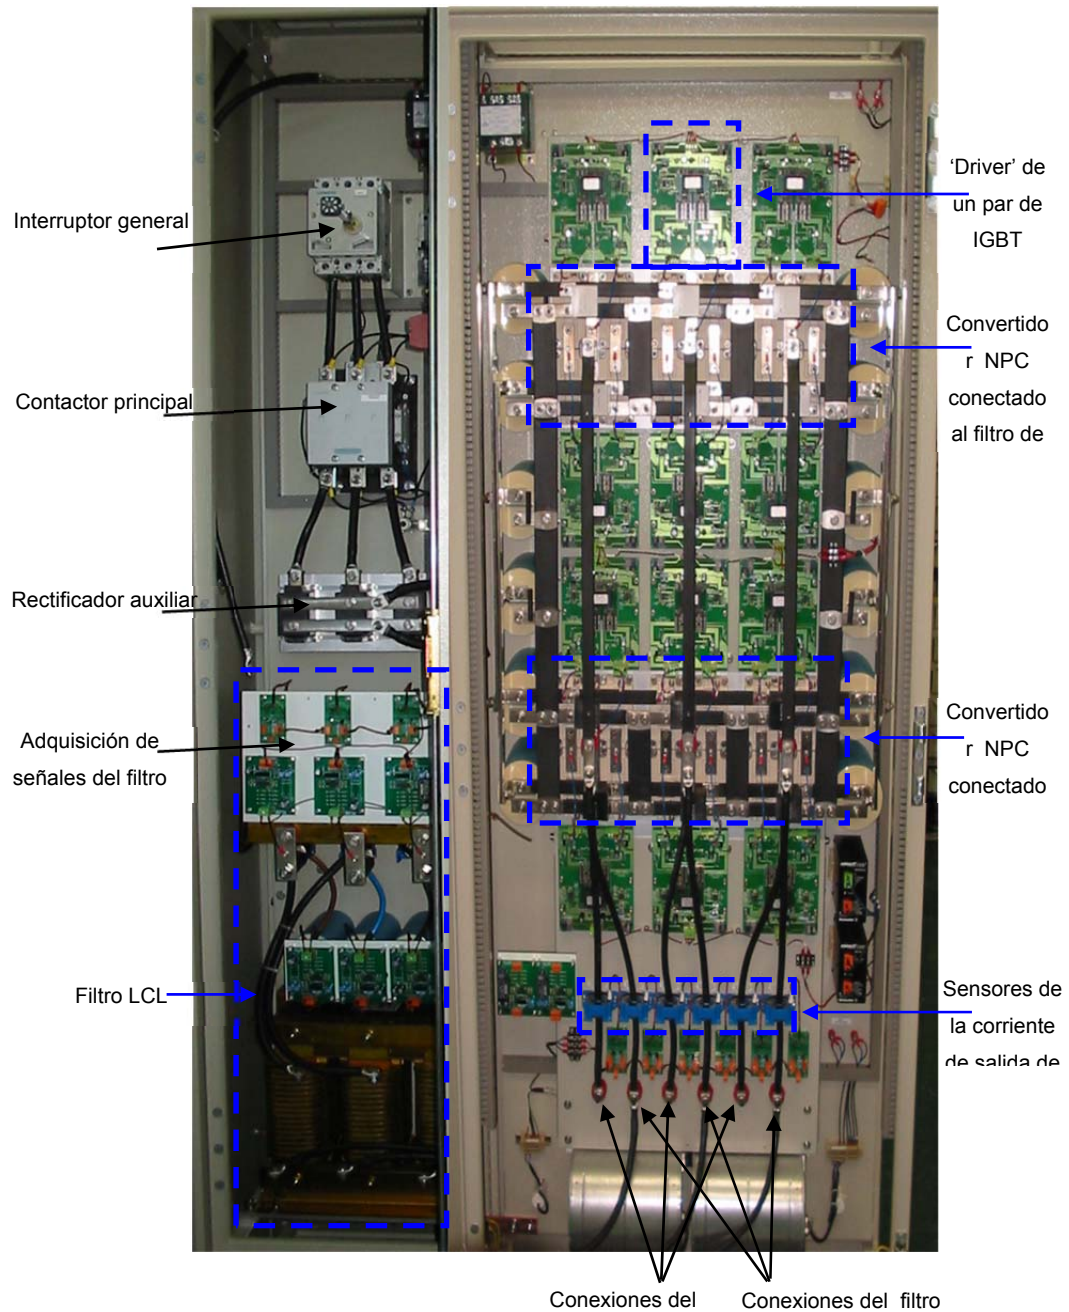


Figura 91. Convertidor 3L-NPC utilizado para la obtención de los resultados experimentales.




Figura 92. Tarjeta FPGA Xilinx ZC702 de desarrollo e interfaz de comunicaciones y muestreo del convertidor.




Figura 93. Tarjeta de interfaz de comunicaciones con el sistema de electrónica de potencia.





Figura 94. Plataforma experimental utilizada para realizar los experimentos.

Las herramientas de diseño utilizadas para el desarrollo del algoritmo, así como de las utilizadas para la simulación y representación de resultados han sido:

- **Xilinx ISE Design Suite 14.6 y Vivado 2016.4:** Utilizadas para depurar la implementación en VHDL del algoritmo, así como para realizar simulaciones funcionales y temporales de los métodos antes de ser probados en la plataforma. Así mismo, junto con la herramienta incorporada Xilinx System Generator (XSG) y HDL Coder de MATLAB, han permitido la generación automática de código VHDL, o permitir realizar co-simulación Hardware junto a MATLAB.
- **ModelSim SE-64 10.1a:** Ha sido la herramienta utilizada para la comprobación de resultados funcional y temporalmente, trabajando conjuntamente con el ISE Design Suite.
- **MATLAB R2016a y Simulink:** MATLAB ha proporcionado una plataforma para modelar sistemas complejos de una forma cómoda y sencilla. En este caso, mediante la toolbox *SimPower System*, se ha podido recrear el modelo analógico del convertidor, para poder simular situaciones de funcionamiento

que no estaban permitidas en la plataforma real, ya sea por propias limitaciones o por no contar con la infraestructura necesaria. Del mismo modo, gracias a la *Neural Network Toolbox*, se ha podido realizar el proceso de entrenamiento *offline* de la red neuronal que se ha aplicado en el modelo adaptativo. Simulink además se integra con el ISE, Vivado y XSG para poder sintetizar bloques de Simulink-XSG en código VHDL.

## 5.5 Introducción de potencia reactiva.

Un caso muy común en convertidores es el de introducir cierto valor de potencia reactiva, ya sea inductiva o capacitiva, en la red eléctrica. Elementos fundamentales como los motores o transformadores, no solo consumen potencia activa, sino que consumen también cierta potencia reactiva que debe ser suministrada y transportada por la propia red. En el caso que aquí nos ocupa, veremos que al introducir potencia reactiva en la red usando el algoritmo MPC, se descompensa el Bus-DC, creándose un desequilibrio en las tensiones de referencias que usa el inversor. Este desequilibrio se traduce en un empeoramiento de los índices de calidad asociados a las corrientes que se generan.

En caso de que se introduzca potencia reactiva  $Q$ , por ejemplo inductiva, se puede mantener la potencia activa  $P$ , siempre que se respete el límite de potencia máxima que pueda aportar el convertidor. Para mostrar mejor los efectos que se producen en la corriente al introducir cierto valor de potencia reactiva, en la Figura 95 se muestra primeramente un ejemplo en el que toda la potencia que se introduce en la red es activa, de un valor  $P^*=100\text{kW}$ , la máxima del convertidor. Por otro lado, en la Figura 96 se muestra qué ocurre cuando se reduce la potencia activa a costa de aumentar la reactiva, concretamente con  $P^*=80\text{kW}$  y  $Q^*=60\text{kVAr}$ . La configuración que se ha usado para estos casos es la siguiente:

Tensión Bus-DC	$V_{DC} = 800 \text{ V}$
Tensión de red eléctrica	$e = 230 \text{ V rms}$
Período de muestreo	$T_s = 100\mu\text{s}$
Resistencia nominal del filtro	$R = 0.063 \Omega$
Inductancia nominal del filtro	$L = 1 \text{ mH}$
Max. Potencia del convertidor	$100 \text{ kVA}$
Factor de peso del desequilibrio Bus-DC	$\lambda_{DC} = 1.2$
Factor de peso de la freq. de conmutación	$\lambda_{SW} = 1$

Comparando ambas figuras, se observa cómo al introducir una potencia reactiva, se produce un desfase de las corrientes con respecto a las tensiones de red. Además, viendo los valores numéricos de las figuras de mérito (índices de calidad), se observa que se produce una ligera degradación de las corrientes con respecto al caso en que solo se introduzca potencia activa. Sin embargo, la figura de mérito que más se ve afectada es el desequilibrio del Bus-DC como veremos a continuación.




Figura 95. Relación entre voltajes de red, referencias de corrientes y corrientes generadas en componentes alfa-beta cuando se le aplica al controlador una referencia de potencia activa  $P = 100kW$ .

Como ya se ha explicado anteriormente, el algoritmo de Control Predictivo Adaptativo propuesto en esta tesis, tiene en su función de coste precisamente un término para ayudar a controlar el desequilibrio que se produce en este bus. Sin embargo, si se configuran los pesos de la función de coste desde el principio del arranque del controlador, y no se modifican una vez comienza a funcionar el controlador (función de

coste estática), en caso de producirse alguna desviación de las figuras de mérito a causa del cambio en las referencias, estos efectos no se podrán corregir. El objetivo de realizar un Control Predictivo con ajuste de los pesos de la función de coste (función de coste dinámica), es precisamente el poder adaptarse a estos cambios y que las corrientes generadas se degraden lo menos posible.

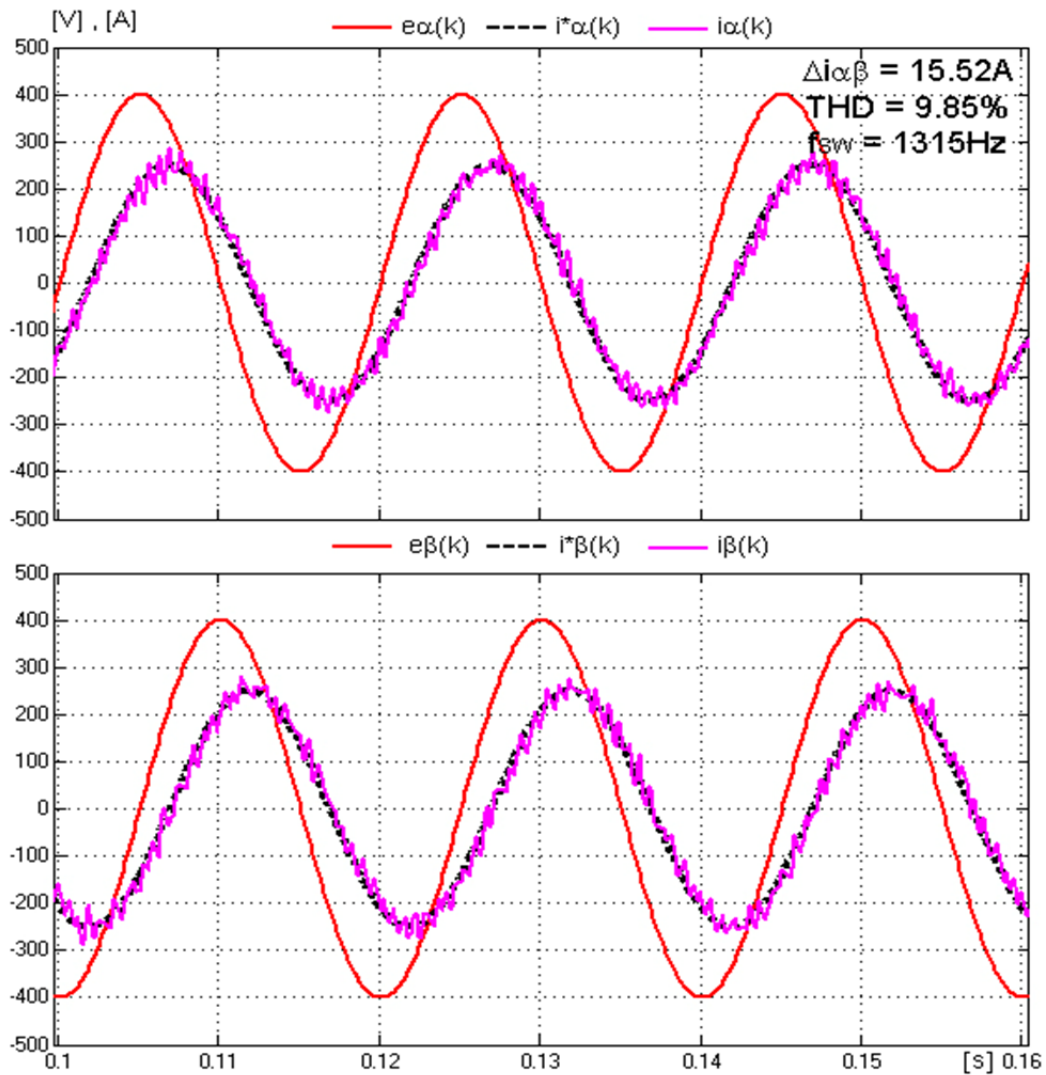


Figura 96 Relación entre voltajes de red, referencias de corrientes y corrientes generadas en componentes alfa-beta cuando se le aplica al controlador unas referencias de potencia activa  $P = 80kW$  y reactiva  $Q = 60kVAr$

La Figura 97, muestra en valor absoluto, el desequilibrio producido en el Bus-DC para ambos casos:  $|V_{C1}(k) - V_{C2}(k)|$ . Claramente se observa, como, cuando toda la potencia que se demanda es activa, el desequilibrio del Bus-DC tanto en media, como en los valores máximos que alcanza, son más bajos. Cuando se introduce potencia reactiva, el desequilibrio es mayor, con valores por encima de los 15 V para la configuración testeada, cuando apenas se llegaban a los 10 V en el caso anterior.




Figura 97. Comparativa del desequilibrio del Bus-DC para el caso de que exista o no potencia reactiva Q.

El algoritmo A-MPC debe ser capaz de corregir dentro de unos márgenes, este efecto. Para evaluar la mejora introducida, se van a considerar dos casos concretos de funcionamiento real sobre la plataforma utilizada:

A) Convertidor controlado por un Algoritmo de Control Predictivo con función de coste estática.

B) El mismo convertidor y configuración, pero ahora con función de coste dinámica utilizando la ANN entrenada, para así poder compensar las degradaciones que se puedan producir.

En ambos casos, los valores de configuración fundamentales del sistema son los mismos y los siguientes:

Tensión Bus-DC	$V_{DC} = 750 \text{ V}$
Tensión de red eléctrica	$e = 230 \text{ V rms}$
Período de muestreo	$T_s = 100\mu\text{s}$
Resistencia nominal del filtro	$R = 0.063 \Omega$



Inductancia nominal del filtro	$L = 1 \text{ mH}$
Max. Potencia del convertidor	100 kVA

Para evidenciar las diferencias entre ambos controladores, se considerará primeramente que ambos sistemas realizan el control con pesos de la función de coste iguales y adecuados para un valor de potencia activa  $P^*$  de 100kW (la total disponible en el convertidor) y  $Q^* = 0\text{kVAr}$ . En este caso  $\lambda_{DC}=1$  y  $\lambda_{SW}=2$ . En cierto momento, se varía la configuración de potencia, pasando a tener una potencia activa  $P^*$  de 80kW y una potencia reactiva  $Q^*$  de 60kVAr, de tal forma que la potencia total o aparente seguirá siendo 100kVA.

En la Figura 98, se muestra la respuesta del sistema A) ante una variación de las consignas de potencia, mostrando además el valor absoluto del desequilibrio del bus-DC. Para un controlador con función de coste estática, las figuras de mérito objetivo (índices de calidad) no son entradas al algoritmo, que solo tendrá como referencias las potencias activa y reactiva. En esta figura, se observa no solo cómo las corrientes de los ejes  $\alpha\beta$  se degradan ligeramente, sino cómo los desequilibrios que se producen en las tensiones de referencia son mayores y las figuras de mérito empeoran todas en general.




Figura 98. Respuesta del sistema A) de un convertidor con pesos fijos ante una variación de consignas de potencia  $P=100\text{kW}$  y  $Q=0\text{kVAr}$ , a  $P=80\text{kW}$  y  $Q=60\text{kVAr}$ .

A continuación, se ha considerado la situación B), en la cual el controlador se base en el algoritmo A-MPC, con una red neuronal entrenada, según lo expuesto en el CAPÍTULO 4. Al producirse los mismos cambios en las referencias de potencia, se ejecuta la red neuronal, y a su salida se obtienen nuevos factores de peso de la función de coste, que hacen que se mantengan las figuras de mérito objetivo. Estas referencias, funcionan a modo de cotas que el sistema no debería sobrepasar.




Figura 99. Respuesta del sistema B) de un convertidor con ajuste de pesos dinámicos ante una variación de consignas de potencia  $P=100\text{kW}$  y  $Q=0\text{kVAr}$ , a  $P=80\text{kW}$  y  $Q=60\text{kVAr}$ .

Como se puede observar en la Figura 99, después de realizarse el cambio, los pesos pasan de  $\lambda_{DC}=1$  y  $\lambda_{SW}=2$ , a  $\lambda_{DC}=1.7$  y  $\lambda_{SW}=0.8$ , lo que se denota que el algoritmo adaptativo, ante el cambio de referencias de potencia realizado, compensa el desequilibrio del Bus-DC, que tiende a aumentar, así como la frecuencia de conmutación de los IGBT que tiende a disminuir. Como se puede ver, el valor de  $\lambda_{DC}$  se ha incrementado, haciendo que este efecto tenga mayor importancia en la función de coste, y por otro lado,  $\lambda_{SW}$  se ha relajado en la justa medida para que no se restrinja la frecuencia de conmutación. Estas variaciones hacen que la red neuronal y el controlador siempre tiendan a contrarrestar las variaciones que se producen, reduciendo o incrementando para ello los factores de peso. Teniendo en cuenta ahora

las referencias de las figuras de mérito deseadas para el sistema, se observa como después del cambio, sus valores se mantienen en niveles muy similares a los había antes del cambio, además de que las degradaciones se corrigen.

Los resultados experimentales sobre el convertidor real para estos dos casos, vienen a consolidar el mismo funcionamiento. En la Figura 100 y Figura 101, se muestra la respuesta sobre la corriente  $i_a$  y el desequilibrio del Bus-DC para el caso de una función de coste estática y dinámica respectivamente. Como se ve, tras el cambio de referencias, las alteraciones en las corrientes son claras, sobre todo en los máximos y mínimos de las señales.




Figura 100. Respuesta obtenida por el controlador sobre la corriente  $i_a$  y desequilibrio del Bus-DC, con una función de coste estática tras aplicar un cambio de referencias de potencia  $P^*=100\text{kW}$  y  $Q^*=0\text{kVAr}$ , a  $P^*=80\text{kW}$  y  $Q^*=60\text{kVAr}$ .




Figura 101. Respuesta obtenida por el controlador sobre la corriente  $i_a$  y desequilibrio del Bus-DC, con una función de coste dinámica tras aplicar un cambio de referencias de potencia  $P=100\text{kW}$  y  $Q=0\text{kVAr}$ , a  $P=80\text{kW}$  y  $Q=60\text{kVAr}$ .

## 5.6 Reducción de potencia

En el apartado anterior se ha visto el caso de introducción de potencia reactiva en las referencias de potencia, manteniendo la potencia total o aparente que aportaba el convertidor. Otro escenario es cuando se produce una reducción de esta potencia. Considerando la misma configuración del sistema que se ha utilizado en el apartado anterior, a saber:

Tensión Bus-DC	$V_{DC} = 750 \text{ V}$
Tensión de red eléctrica	$e = 230 \text{ V rms}$
Período de muestreo	$T_s = 100\mu\text{s}$
Resistencia nominal del filtro	$R = 0.063 \Omega$
Inductancia nominal del filtro	$L = 1 \text{ mH}$
Max. Potencia del convertidor	100 kVA

Se ha realizado un experimento en el que la referencia de potencia pasa del valor máximo admitido por el convertidor  $P^*=100\text{kW}$  ( $Q^*=0\text{kVAr}$ ), a un 40% de dicho valor, esto es, pasando a ser de  $P^*=60\text{kW}$  ( $Q^*=0\text{kVAr}$ ). Igual que antes, se realizó el experimento en la situación A), con un algoritmo MPC clásico y función de coste estática, y posteriormente el caso B) con un algoritmo A-MPC con función de coste

dinámica. En todos estos casos, las referencias de las figuras de mérito que se han considerado han sido:  $\Delta i_{q\beta^*}=18A$ ,  $THD^*=11\%$ ,  $\Delta V_c^*=12V$  y  $f_{sw}^*=1700Hz$ . Como ya se ha comentado, el sistema adaptativo basado en la ANN, proporcionará los factores de peso de la función de coste para que el comportamiento del inversor se acerque lo más próximo posible a los objetivos de control, sin sobrepasarlos.

La Figura 102, muestra el caso del algoritmo con función de coste estática, en el que los factores de peso no se modifican y están ajustados para trabajar con  $P^*=100kW$ , con valores  $\lambda_{DC}=1$  y  $\lambda_{SW}=2$ . Como se observa al ver los índices de calidad de la figura para cada instante, reducir el nivel de potencia exigido al convertidor controlado, afecta aumentando la distorsión de las señales, sobretodo el THD, debido a que los armónicos pasan a ser mayores en relación al armónico principal, que es el que se ve reducido por la reducción de la potencia. Ello conlleva un aumento del THD. La desviación de corriente se reduce, pero por el mismo motivo que antes, se debe a que el orden de magnitud de las señales se reduce por igual respecto a las referencias, al reducirse la potencia de referencia. Es decir, si el rango dinámico de las señales se reduce, su error también lo hace. En oposición a las dos anteriores figuras de mérito, el desequilibrio del Bus-DC  $\Delta V_c$  se reduce, y la frecuencia de conmutación  $f_{sw}$  disminuye también.




Figura 102. Respuesta del sistema para el caso A) de un convertidor con pesos fijos ante una variación de consignas de potencia  $P=100kW$  y  $Q=0kVar$ , a  $P=60kW$  y  $Q=0kVar$ .

Si se aplica ahora el algoritmo A-MPC con función de coste dinámica, es decir, el caso B), para intentar mantener los valores de las figuras de mérito que se tenían antes del cambio, se reducen los factores de peso del desequilibrio del Bus-DC y de la frecuencia de conmutación. Al reducir el peso de estos términos sobre el tracking, se consigue una mejora del mismo, lo que se traduce en que la distorsión de la corriente es menor. La explicación más obvia es que al poder tener más libertad para conmutar entre estados que provoquen un aumento del desequilibrio, o una frecuencia mayor, se puede a la vez conmutar entre un mayor rango de estados del convertidor, aquellos que permitan mejorar el tracking. La Figura 103 muestra las respuestas obtenidas en las corrientes tras aplicar el algoritmo A-MPC con la ANN entrenada. Como vemos, los factores de peso han variado de  $\lambda_{DC}=1$  y  $\lambda_{SW}=2$ , a  $\lambda_{DC}=0.5$  y  $\lambda_{SW}=1.7$ . Tanto el desequilibrio del Bus-DC como la frecuencia de conmutación vuelven a tomar valores similares, y además se ha reducido el THD en 2 puntos porcentuales.




Figura 103. Respuesta del sistema para el caso B) de un convertidor con ajuste de pesos dinámicos ante una variación de consignas de potencia  $P^*=100\text{kW}$  y  $Q^*=0\text{kVar}$ , a  $P^*=60\text{kW}$  y  $Q^*=0\text{kVar}$ .



## 5.7 Funcionamiento continuo con cambios de referencias de potencia

Para ver más claramente el efecto del algoritmo A-MPC cuando se realizan cambios de referencia de las potencias, tanto al introducir potencia reactiva  $Q$ , como al reducir el nivel total de potencia exigida, se evaluarán los efectos sobre las figuras de mérito y el funcionamiento del sistema, cuando se producen varios cambios consecutivos. Para ello, se consideran tres escenarios de referencias de potencia:

- a)  $P^*=100\text{kW}$   $Q^*=0\text{kVAr}$
- b)  $P^*=60\text{kW}$   $Q^*=80\text{kVAr}$
- c)  $P^*=80\text{kW}$   $Q^*=0\text{kVAr}$

Las referencias de las figuras de mérito son las mismas que se impusieron en los dos apartados anteriores:  $\Delta i_{\alpha\beta}^*=18\text{A}$ ,  $\text{THD}^*=11\%$ ,  $\Delta V_c^*=12\text{V}$  y  $f_{\text{sw}}^*=1700\text{Hz}$ . Los valores de los parámetros de la planta para el experimento son los mismos también. El objetivo del experimento es comprobar cómo las figuras de mérito se mantienen respecto a la primera configuración (con  $P^*=100\text{kW}$ ). Se debe tener en cuenta que, en el caso de la reducción de la potencia total, al reducirse los niveles de las corrientes, se verá un mayor cambio en el THD como ya se explicó en el apartado anterior.

La Figura 104 muestra el resultado de la aplicación de los tres casos de consignas, donde se muestran, las dos corrientes generadas en componentes  $\alpha\beta$  a la vez que sus referencias, así como el desequilibrio del Bus-DC y los valores de la frecuencia de conmutación de los transistores IGBT. Como se observa, la desviación media de corrientes  $\Delta i_{\alpha\beta}$  permanece con valores muy similares durante todo el experimento para los tres casos de consignas. El THD se mantiene casi constante al introducir la potencia reactiva (caso b), pero en cambio es inevitable su aumento en el tercer caso de reducción de potencia (caso c) por las razones ya explicadas. El desequilibrio del Bus-DC  $\Delta V_c$  oscila más para los tres casos, aunque siempre se mantiene en el mismo orden en torno a la referencia  $\Delta V_c^*$ . La principal causa es que, como se ha visto, este parámetro es muy dependiente de la potencia, y no para todos los puntos se pueden obtener cualquier valor de desequilibrio medio. Existen configuraciones de potencia en las que el desequilibrio no baja de cierta cota, según se describió en el CAPÍTULO 3. Como se observa, el desequilibrio aumenta al introducir potencia reactiva, mientras que disminuye para el caso de reducción de la potencia.






Figura 104. Respuesta continua del controlador A-MPC con ajuste de pesos dinámicos ante tres variaciones de consignas de potencia  $P^*=100\text{kW}$  y  $Q^*=0\text{kVar}$ ,  $P^*=60\text{kW}$  y  $Q^*=80\text{kVar}$  y por último  $P^*=100\text{kW}$  y  $Q^*=0\text{kVar}$ .

No obstante, con el algoritmo A-MPC y mediante la ANN, nos aseguramos que funcione de tal manera que se acerque lo máximo posible a la referencia. Por último, la frecuencia de conmutación media de los IGBT  $f_{sw}$  oscila siempre en torno a los 1600Hz para ambos casos sin superar la cota de los 1700Hz de referencia. Esta afirmación se puede ver claramente en la variación de la frecuencia de conmutación instantánea mostrada en la Figura 104. Como se ve, el algoritmo A-MPC ha encontrado para cada sección de prueba, su combinación de factores adecuados, que en este caso han sido:

- a)  $P^*=100\text{kW}$   $Q^*=0\text{kVAr}$ :  $\lambda_{DC}=1$   $\lambda_{SW}=2$
- b)  $P^*=60\text{kW}$   $Q^*=80\text{kVAr}$ :  $\lambda_{DC}=1.2$   $\lambda_{SW}=0.6$
- c)  $P^*=80\text{kW}$   $Q^*=0\text{kVAr}$ :  $\lambda_{DC}=0.9$   $\lambda_{SW}=1.8$

En la Figura 105 se muestra el efecto sobre la corriente de red generada  $i_a$ , donde se han incluido las mediciones de las desviaciones medias de corriente, el THD y los desequilibrios del Bus-DC medidos para los tres casos de configuraciones de potencia. Además, se obtuvieron las frecuencias de conmutación media para los tres casos en base a los cambios reales de estados producidos durante todo el funcionamiento, siendo de  $f_{sw}=1589\text{Hz}$  para el caso a),  $f_{sw}=1523\text{Hz}$  para el b) y  $f_{sw}=1745\text{Hz}$  para el c).




Figura 105. Respuesta continua sobre la corriente  $i_a$  para los tres cambios de referencias de potencia planteados en el experimento.

## 5.8 Cambio de referencia de la frecuencia de conmutación

Una vez se han mostrado los resultados experimentales cuando se realizan cambios en las referencias de potencia, a continuación se mostrará el caso en el que se desea cambiar la referencia de la frecuencia de conmutación de los IGBT, es decir  $f_{sw}^*$ . El controlador se ha testado con la siguiente configuración para la planta:

Tensión Bus-DC	$V_{DC} = 750 \text{ V}$
Tensión de red eléctrica	$e = 230 \text{ V rms}$
Período de muestreo	$T_s = 100\mu\text{s}$
Resistencia nominal del filtro	$R = 0.063 \Omega$
Inductancia nominal del filtro	$L = 1 \text{ mH}$
Referencia de potencia activa $P^*$	100 kWA
Referencia de potencia reactiva $Q^*$	0 kVAr
Referencia de desviación de corrientes $\Delta i_{\alpha\beta}^*$	15 A
Referencia de THD*	11 %
Referencia de desequilibrio del Bus-DC $\Delta V_C^*$	10 V
Referencia de frec. de conmutación $f_{sw}^*$	1700 $\rightarrow$ 1600 Hz

El experimento consiste en cambiar entre dos referencias de frecuencia de conmutación  $f_{sw}^*$ , teniendo en primera instancia una referencia de 1700Hz, y a continuación, pasar a los 1600 Hz.

Para el caso de  $f_{sw}^*=1700\text{Hz}$ , la respuesta sobre la corriente  $i_a$ , así como la tensión  $V_{A0}$  de salida para esa rama, se muestran en la Figura 106. Para esta configuración según las referencias, los factores de peso encontrados por el algoritmo A-MPC fueron de  $\lambda_{DC}=0.8$  y  $\lambda_{sw}=2.4$ .

Analizando la tensión  $V_{A0}$ , se puede obtener una aproximación de la frecuencia de conmutación de los IGBT, ya que, de forma general, un cambio de tensión está asociado a un cambio de estado, y, por tanto, a conmutaciones en los transistores implicados en dicho cambio. Como se vio en el apartado 2.2.9, el número de conmutaciones que se producen dependerá de cada par de estados implicados en la transición. Por otro lado, una vez el algoritmo A-MPC está funcionando en régimen permanente bajo unas determinadas consignas para generar unas corrientes estables, podemos considerar que mientras más cambios se observen en las tensiones de salida  $V_{A0}$ ,  $V_{B0}$  y  $V_{C0}$ , mayores serán las conmutaciones que se producen en los IGBT.

Aun así, para este primer caso con  $f_{sw}^*=1700\text{Hz}$ , se ha calculado la frecuencia de conmutación media de los IGBT, y esta fue de  **$f_{sw}=1724\text{Hz}$** , muy similar a la referencia. Los índices de calidad o figuras de mérito obtenidas fueron así mismo:

- $\Delta\alpha\beta = 15.04 \text{ A}$
- $\text{THD} = 10.2\%$
- $\Delta V_c = 9.46 \text{ V}$
- $f_{sw} = 1724 \text{ Hz}$




Figura 106. Tensión de salida del convertidor, y corriente generada para la fase 'a' de la red eléctrica, para una referencia de frecuencia de conmutación de 1700Hz.

A continuación, se realizó el mismo experimento, pero ahora aplicando una referencia de frecuencia de conmutación más baja de  **$f_{sw}^*=1600\text{Hz}$** . Manteniendo las demás referencias, los factores de peso en A-MCP fueron de  $\lambda_{DC}=0.91$  y  $\lambda_{sw}=3.6$ . Como cabía esperar, el algoritmo adaptativo ha aumentado el factor de peso  $\lambda_{sw}$  a fin de que este parámetro tuviese más peso en la función de coste, y por tanto se redujera la frecuencia de conmutación. Así mismo,  $\lambda_{DC}$  ha aumentado ligeramente, pues al limitar el número de conmutaciones, también queda limitado el número de cambios entre estados que se puedan hacer, provocando que el inversor oscile entre estados que provocan mayores desequilibrios del Bus-DC. Por otro lado, aumentando ligeramente  $\lambda_{DC}$ , el controlador ha conseguido mantener el desequilibrio  $\Delta V_c$  estable al igual que

las demás figuras de mérito. La Figura 107, muestra la tensión de salida  $V_{A0}$  y la corriente  $i_a$  obtenida para este caso.




Figura 107. Tensión de salida del convertidor, y corriente generada para la fase 'a' de la red eléctrica, para una referencia de frecuencia de conmutación de 1600Hz.

Comparando la tensión de salida del inversor con el caso anterior, se observa como el número de transiciones de niveles es menor, y por tanto el número de cambios de estado también, sobre todo durante los pasos por cero de la corriente, donde antes se producían mayores conmutaciones y esto provocaba mayores alteraciones en la corriente. Estas reducciones, provocan una mejora en las desviaciones de corrientes respecto a las referencias, y un THD más bajo. Concretamente para este segundo caso, los índices de calidad obtenidos fueron:

- $\Delta i_{\alpha\beta} = 14.55 \text{ A}$
- $\text{THD} = 9.48\%$
- $\Delta V_c = 10.02 \text{ V}$
- $f_{\text{SW}} = 1604 \text{ Hz}$

En la Figura 108 se muestra una comparativa de la evolución del estado óptimo encontrado durante la evolución del control para ambos casos estudiados: una referencia de  $f_{\text{SW}}^* = 1700 \text{ Hz}$  y de  $f_{\text{SW}}^* = 1600 \text{ Hz}$ . Como se observa, cuando la referencia

de frecuencia se restringe más, se limitan las transiciones entre estados lejanos, y cuando se relaja, se ve cómo se producen más transiciones entre estados no cercanos, y a la vez se producen más cambios por segundo.




Figura 108. Diferencias en la conmutación entre estados para el caso estudiado con  $f_{sw}^*=1700\text{Hz}$  y  $f_{sw}^*=1600\text{Hz}$ .

## 5.9 Cambio de referencia del desequilibrio del Bus-DC

En este apartado se plantea un nuevo escenario consistente en un cambio en la referencia del desequilibrio medio en el Bus-DC. Para este caso, la configuración del sistema es la misma que para el apartado anterior, salvo que ahora se mantienen constantes todas las demás, excepto la del desequilibrio:

Tensión Bus-DC	$V_{DC} = 750\text{ V}$
Tensión de red eléctrica	$e = 230\text{ V rms}$
Período de muestreo	$T_s = 100\mu\text{s}$
Resistencia nominal del filtro	$R = 0.063\ \Omega$
Inductancia nominal del filtro	$L = 1\text{ mH}$
Referencia de potencia activa $P^*$	100 kWA
Referencia de potencia reactiva $Q^*$	0 kVAr

Referencia de desviación de corrientes $\Delta i_{\alpha\beta}^*$	15 A
Referencia de THD*	11 %
Referencia de frec. de conmutación $f_{sw}^*$	1700 Hz
Referencia de desequilibrio del Bus-DC $\Delta V_c^*$	15 $\rightarrow$ 10 $\rightarrow$ 5 V

Para este experimento, se partirá desde una referencia de desequilibrio medio de  $\Delta V_c^*=15$  V, para el cual el controlador A-MPC obtuvo unos factores de peso para la función de coste de  $\lambda_{DC}=0.65$  y  $\lambda_{sw}=2.5$  y unos índices de calidad de funcionamiento del sistema de:

- $\Delta i_{\alpha\beta} = 14.85$  A
- THD = 10.28%
- $\Delta V_c = 13.83$  V
- $f_{sw} = 1687$  Hz

En la Figura 109 se muestra la corriente generada y el desequilibrio del Bus-DC para este caso. En ella se aprecia que, aunque el Bus-DC tiene algunos picos de desequilibrio, su valor medio está cercano a los 15V configurados por la referencia.




Figura 109. Corriente  $i_a$  generada y desequilibrio del Bus-DC del controlador A-MPC con  $\Delta V_c^*=15$ V.

A continuación, se cambia a una referencia de  $\Delta V_c^* = 10 \text{ V}$  coincidiendo con el ejemplo del apartado anterior, en el que los factores de peso más adecuados para obtener las características obtenidas eran  $\lambda_{DC} = 0.8$  y  $\lambda_{SW} = 2.4$ . En esta ocasión, los factores de calidad quedaron muy parecidos a los que se obtuvieron, salvo por las variaciones propias debidas a las pequeñas fluctuaciones de los valores implicados en el funcionamiento:

- $\Delta i_{\alpha\beta} = 14.43 \text{ A}$
- THD = 9.98%
- $\Delta V_c = 9.64 \text{ V}$
- $f_{SW} = 1725 \text{ Hz}$




Figura 110. Corriente  $i_a$  generada y desequilibrio del Bus-DC del controlador A-MPC con  $\Delta V_c^* = 10 \text{ V}$ .

En la Figura 110 se muestra la corriente  $i_a$  y el desequilibrio del Bus-DC, observándose que ha habido una reducción clara de este, sin apenas variar el resto de índices de calidad respecto al caso anterior. En este caso,  $\lambda_{DC}$  ha aumentado para corregir el exceso de desequilibrio, y  $\lambda_{SW}$  apenas ha variado su valor, si bien ha disminuido.



Por último, se realiza el experimento con una referencia  $\Delta V_c^*=5$  V en el que se ha intentado reducir al máximo el desequilibrio que se puede tener en el Bus-DC. Para este caso, el controlador A-MPC obtuvo unos factores de peso de  $\lambda_{DC}=1.4$  y  $\lambda_{SW}=4.09$  y unos parámetros de:

- $\Delta i_{\alpha\beta} = 16.21$  A
- THD = 11.29%
- $\Delta V_c = 6.49$  V
- $f_{SW} = 1705$  Hz




Figura 111. Corriente  $i_a$  generada y desequilibrio del Bus-DC del controlador A-MPC con  $\Delta V_c^*=5$ V.

En la Figura 111 se ve claramente el empeoramiento que ha habido en la corriente  $i_a$  a costa de reducir el desequilibrio producido en el Bus-DC. En este caso, el controlador A-MPC ha aumentado el factor de peso del desequilibrio desde  $\lambda_{DC}=0.8$  a  $\lambda_{DC}=1.4$ , y de igual manera el factor de control de la frecuencia de conmutación ha aumentado desde  $\lambda_{SW}=2.4$  a  $\lambda_{SW}=4.09$ , lo que implica que en esta situación de exigencia de las referencias, la frecuencia tendía a aumentar y se ha tenido que reducir para cumplir con la referencia de 1700Hz. El aumento de la desviación de corriente respecto a los 15 A que se marcaron, es debido al propio error cometido por las redes neuronales al buscar el punto de trabajo que más se asemeje. No obstante en este caso y a la vista

de los resultados, estos indican claramente que no se podría seguir restringiendo tanto el desequilibrio del Bus-DC, a la vez que se mantienen el resto de índices de calidad estables.

## CAPÍTULO 6. CONCLUSIONES FINALES

En esta tesis se ha propuesto, implementado y probado un esquema de Control Predictivo aplicado a un inversor 3L-NPC, que ha demostrado ser un método eficiente para realizar el control en convertidores de potencia. Se ha evidenciado que este algoritmo tiene múltiples ventajas sobre otros esquemas de control, como los basados en modulación por anchura de pulsos. Por mencionar algunas de las más importantes:

- Es un método que reduce el diseño del controlador a la obtención de un modelo matemático del circuito eléctrico formado por el convertidor conectado a la red, para predecir el comportamiento futuro; y a la optimización de una función de coste, mediante la exploración completa del espacio de posibles estados. Esta sencillez, permite incluir varios objetivos de control como en este caso han sido el desequilibrio del Bus-DC y la frecuencia de conmutación de los IGBTs (ver apartado 2.2.6).
- Si se implementa en una FPGA como en este caso, permite hacer uso de la potencia de cálculo y velocidad de estos dispositivos a la hora de explorar el espacio de estados para obtener la predicción, ya que, al tratarse de modelos matemáticos, se trabaja con señales digitales acotadas y conocidas. Además, al usar FPGA, los tiempos de actuación y respuesta son determinísticos con muy poco jitter, al contrario de lo que sucede cuando se usan DSP. Por otro lado, los tiempos de actuación del algoritmo A-MPC frente a cambios de consigna están en torno a 2 y 7 ms con un comportamiento sobre-amortiguado (ver apartado 2.5.1).
- El control que realiza no se basa en el error cometido en la muestra anterior, sino en la predicción del error que se cometerá. Por ello, como el tiempo de evaluación del algoritmo es siempre el mismo (120 ciclos de reloj con el diseño implementado), el nuevo estado de conmutación se aplica antes del siguiente período de muestreo. Esto plantea un cambio sustancial con respecto a sistemas implementados en DSP, en los que se aplica el cambio de actuación en el siguiente período, con una latencia de un ciclo.

- Es un algoritmo poco costoso de desarrollar e implementar, debido a que se trata con modelos matemáticos, normalmente fáciles de convertir en multiplicaciones y sumas, con pocas operaciones no lineales. Esto permite que se puedan diseñar usando herramientas visuales como XSG o Simulink, con las que se genera automáticamente código VHDL, o incluso el *bitstream* para grabar en la placa.

Por contra, el algoritmo MPC plantea una serie de inconvenientes que hay que tener muy en cuenta:

- Al implementarse en una FPGA, y por tanto tener que hacer uso de valores en punto fijo, se producen errores de cuantificación que pueden influir negativamente en el comportamiento del controlador. Se debe por tanto llegar a un compromiso de diseño, entre los errores admisibles y la anchura de datos. En nuestro caso, los resultados han sido aceptables usando una anchura de 18 bits, para la cual estaba optimizada la FPGA utilizada.
- El uso de algunas funciones no lineales indispensables, como son el caso de las funciones *coseno*, *seno* y la división durante la generación de las consignas y el funcionamiento del FSR-PLL, obligan a usar tablas de valores precalculados. Estas tablas introducirán implícitamente errores de cuantificación dependientes del número de puntos de las mismas o escalón de cuantificación.
- El algoritmo MPC es sensible a los errores de modelado de los parámetros del inversor, que se usan en el modelo matemático para realizar las predicciones. El algoritmo es especialmente sensible a la variación de la inductancia de red  $L$ , y a la propia tensión. Otros valores que afectan en gran medida son el período de muestreo  $T_s$ , (aunque no es habitual que varíe), y la tensión total del Bus-DC  $V_{DC}$ , que depende de las prestaciones del controlador de la parte rectificadora del convertidor back-to-back, y no del inversor (ver apartado 2.4).
- Para cada configuración de potencia, el sistema se comporta de una determinada manera, y esta respuesta no es fácil de modelar. Esto se ve claramente en parámetros como la frecuencia de conmutación de los IGBT, la cual cambia en función de la magnitud de las corrientes que se exigen, o del

desfase respecto a las tensiones, es decir, la potencia reactiva  $Q$  (ver apartado 2.3).

Viendo los posibles inconvenientes que plantea el algoritmo MPC, en esta tesis se planteó como objetivo principal, encontrar formas de eliminar o reducir alguno de los inconvenientes encontrados. En resumen, optimizar el funcionamiento del algoritmo sobre convertidor 3L-NPC. Algunos problemas son difíciles de evitar por completo, como el error de cuantificación y otros son complicados de evaluar, como es el caso de la variación del valor de la inductancia  $L$  (ver apartado 2.4.1). Sin embargo, los problemas asociados a los cambios de referencias de potencia, si se han podido abordar, así como encontrar la manera de mejorar el funcionamiento del algoritmo cuando estos se producen. Para evaluar dicho comportamiento, se definieron unos índices de calidad, o figuras de mérito, que nos ayudaron a incluir la mayoría de los efectos del sistema (ver apartado 3.1).

El objetivo de la optimización es la función de coste del algoritmo MPC, en la que se cuantifican los objetivos de control, ponderándolos con factores de peso:  $\lambda_{\text{TRACKING}}$  fijada a 1,  $\lambda_{\text{DC}}$  y  $\lambda_{\text{SW}}$ . Como se ha demostrado en esta tesis, para poder abordar el problema, es necesario caracterizar la relación que existe entre las variables que intervienen: referencias de potencia, factores de peso e índices de calidad. En este trabajo se ha visto la variación de todos los parámetros que intervienen en el algoritmo MPC clásico sobre un inversor 3L-NPC, demostrando y explicando el porqué de cada una de dichas relaciones. Con todos estos resultados, se construyó una base de datos con registros que contienen las observaciones para diferentes configuraciones de potencia con diferentes factores de peso, calculándose para cada uno de ellos los índices de calidad previamente definidos (ver apartado 3.3.3).

Con la obtención de la base de datos, se ha propuesto una modificación del algoritmo MPC para hacerlo adaptativo, ajustando los factores de peso a cada configuración posible de potencia, incluyendo además objetivos de control cuantificados como los índices de calidad deseados para el sistema (ver apartado 3.2).

Para modelar las relaciones entre las referencias y los factores de peso, se ha realizado un estudio detallado de posibles alternativas que permitan solucionar un problema claramente no lineal. De todas las posibles soluciones, se han descartado aquellas que difícilmente podrían ser implementadas en el hardware de procesamiento habitual en un inversor, debido a que contemplan operaciones no lineales o necesitan

excesivos recursos. No se debe olvidar que el controlador adaptativo está diseñado para su implementación en una FPGA. Se han evaluado una serie de modelos factibles de implementar implementación como la regresión lineal múltiple (ver apartado 3.4.1), redes neuronales artificiales de propagación hacia adelante, redes recursivas (ver apartado 3.4.2) o la lógica difusa (ver apartado 3.4.3). Partiendo de los resultados obtenidos, se ha optado por una red neuronal de propagación hacia adelante, o *Feed-forward Artificial Neural Network* (FF-ANN).

Durante el CAPÍTULO 4 se ha estudiado el diseño, entrenamiento y evaluación de la FF-ANN, realizando un diseño específico para implementar el controlador adaptativo, logrando un compromiso entre el número de recursos consumidos para implementar la red y los resultados obtenidos. Se ha mostrado cómo, en primera instancia, aumentando la complejidad y por tanto los recursos, se consigue aumentar o mejorar los resultados. Sin embargo, llega un punto en que por más que se aumente la complejidad no se mejoran los resultados.

Con la FF-ANN implementada, se ha modificado el controlador clásico estudiado en el CAPÍTULO 2, para hacerlo adaptativo, conformando un algoritmo capaz de adaptar los pesos de la función de coste. Con esta inclusión, se ha conformado lo que se ha bautizado con el nombre de algoritmo de Control Predictivo Adaptativo, o *Adaptive Model Predictive Controller* (A-MPC), aplicado para inversores 3L-NPC. En el CAPÍTULO 5, se han mostrado diferentes escenarios de funcionamiento del A-MPC, quedando demostrada la mejora en las prestaciones del controlador al adaptar los pesos de la función de coste, dentro de un margen de actuación.

Por todo ello, se consideran alcanzados los objetivos planteados al comienzo de la tesis.

## **6.1 Trabajos futuros**

La presente tesis doctoral se ha centrado en convertidores de potencia muy específicos, en este caso del tipo 3L-NPC. No obstante, la metodología descrita puede extrapolarse a cualquier otro convertidor, siempre que este admita la implementación de un Control Predictivo. Para ello, el requisito fundamental, es que se pueda describir mediante una expresión matemática dependiente de la variación del tiempo ( $d/dt$ ), el valor de las corrientes generadas por el convertidor. Por ello, es factible el uso de este método en otro tipo de convertidores.

Así mismo, el algoritmo A-MPC puede mejorarse introduciendo nuevos objetivos de control que no han sido abordados en esta tesis. Cabe destacar sobretodo, que se puede mejorar el controlador para hacerlo más robusto ante la variación de ciertos parámetros, en especial los valores de inductancia y resistencia de la impedancia equivalente de red.

## 6.2 Contribuciones y Publicaciones Asociadas

Las propuestas y contribuciones de esta tesis han sido publicadas en revistas internacionales y en varios congresos nacionales e internacionales:

### Artículos de Revistas

1. ***FPGA-Based Implementation of a Predictive Current Controller for Power Converters.*** IEEE Transactions on Industrial Informatics. 2013. Índice de Impacto 8.785. Revista número 1 en el JCR en las categorías de Automation and Control Systems; Computer Science, Interdisciplinary Applications; e Industrial Engineering. Citado 33 veces, según consulta a Google Scholar el 21 de marzo de 2017.

En este artículo se expone la implementación en FPGA del algoritmo de control predictivo sobre el convertidor 3L-NPC utilizado en este trabajo. En este estudio realizado, como paso previo a la propuesta de optimización del algoritmo A-MPC aquí expuesto, se ponen de manifiesto las ventajas y desventajas del algoritmo, así como los resultados obtenidos al generar las corrientes de red demandadas.

2. ***An FPGA-Based Approach to the Automatic Generation of VHDL Code.*** Mathematics and Computers in Simulation. 2013. Índice de Impacto 0.856. Revista número 104 (Q2) en el JCR en la categoría de Applied Mathematics. Citado 5 veces, según consulta a Google Scholar el 21 de marzo de 2017.

Este trabajo está enfocado en mostrar el método utilizado para la generación automática, y eficiente, del código VHDL usado en la implementación del algoritmo de Control Predictivo sobre el convertidor 3L-NPC usado en esta tesis.

3. **A Neural Network-based Dynamic Cost Function for the Implementation of a Predictive Current Controller.** IEEE Transaction on Industrial Informatics. 2017. (Aceptado y pendiente de publicación final).

Esta publicación muestra de manera menos profunda, los resultados obtenidos en esta tesis, exponiendo la propuesta de optimización del algoritmo de Control Predictivo basado en la utilización de una red neuronal artificial para obtener los factores de peso de la función de coste.

#### **Capítulos de Libros y Congresos**

1. **FPGA-based approach for the parallelization of a Predictive Current Controller Algorithm.** ELECTRIMACS 2014.
2. ***Design Space Exploration for the Implementation of a Predictive Current Controller Based on FPGA.*** 23<sup>rd</sup> IEEE Conference on Application-Specific System, Architectures and Processors (ASAP) 2012. Delft. Holanda.
3. ***Optimization of System Generator Implementation for FPGA-Based Control Systems.*** ELECTRIMACS 2011. París. Francia.
4. ***Automatic Generation of Optimal VHDL Code Based on Constraints from XSG Specifications.*** CEDI 2010. Valencia. España.



# APÉNDICE I

## Creación e inicialización de una red neuronal Perceptrón Multicapa en MATLAB

La función ***newff*** (feed-forward backpropagation network) de MATLAB, permite la creación de una red neuronal Perceptrón Multicapa tal como se ha descrito en este punto. Para ello se le deben especificar los valores máximos y mínimos de cada una de sus entradas, obtenidos directamente a partir de los patrones de entrenamiento de la base de datos. También se le deben especificar el tipo de función de transferencia de las neuronas de la capa oculta o intermedia, y los de la capa de salida. Para este tipo de redes neuronales, los mejores resultados se obtienen con una función de transferencia **Tangente-Sigmoidal** para la capa oculta, y una **función lineal** para las neuronas de la capa de salida (65). Por último, se debe especificar el número de neuronas que se deben tener en la capa oculta.

## Entrenamiento de Redes Neuronales utilizando MATLAB

Realizar el entrenamiento de las redes neuronales artificiales manualmente o mediante la creación de un software específico diseñado para tal fin, puede ser una tarea lenta, tediosa y compleja. Por ello, en este trabajo se hizo uso de las herramientas aportadas por la plataforma Neural Network Toolbox de MATLAB.

Con la función ***train*** de la toolbox *Neural Network*, se puede realizar el entrenamiento de la ANN, pasándole como parámetros de entrada la estructura de la red neuronal creada con ***newff***, y los patrones de entrada y las salidas de entrenamientos de la base de datos en forma matricial.

Al comenzar el entrenamiento, la toolbox de MATLAB informa durante todo el proceso de la evolución de los objetivos prefijados y el seguimiento del proceso del mismo. Cuando el propio algoritmo detecta que se ha encontrado el punto óptimo, en el cual no se consigue una mejora del MSE, detiene automáticamente el proceso y lo da por concluido sin tener que completar las 500 iteraciones. Ello hace que no se produzca un sobre-entrenamiento. La Figura 112 muestra una imagen de esta toolbox de entrenamiento de MATLAB para redes neuronales durante su ejecución.

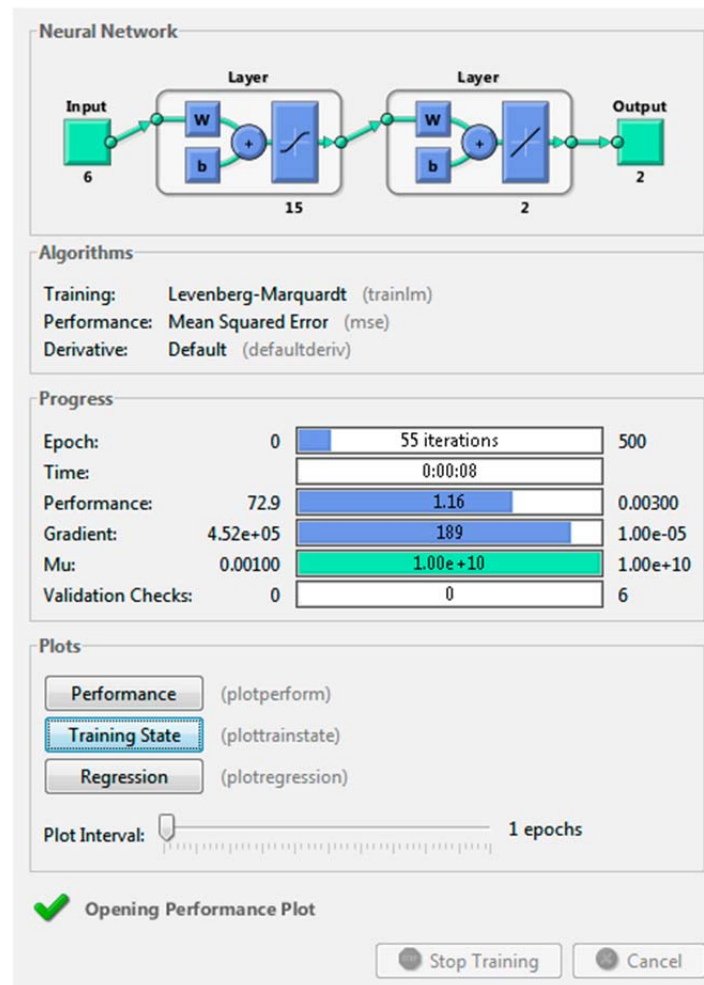


Figura 112. Interfaz de entrenamiento de la *toolbox Neural Network* de MATLAB.




Figura 113. Evolución del error cuadrático medio o MSE durante el proceso de entrenamiento.

Así mismo, la evolución del error cuadrático medio durante el entrenamiento se muestra en la Figura 113, donde se ve el punto en el cual el algoritmo ha parado el entrenamiento. En este caso, después de las 55 iteraciones, se ha parado el entrenamiento automáticamente.

## Simulación de las redes FF-ANN desde MATLAB

Para simular el comportamiento de la red neuronal entrenada, se hace uso de la función **sim** de la toolbox *Neural Network*, a la cual se le pasan los patrones de entrada que no se han usado para el entrenamiento de la misma, es decir, los patrones de validación, y al final se comparan los resultados obtenidos por la red neuronal respecto a dichos valores. En objetivo de aplicar patrones no usados para el entrenamiento, es ver la capacidad de respuesta que tiene la red neuronal para valores no conocidos. La opción de separar parte de patrones para el entrenamiento, y otra para la validación, lo puede hacer automáticamente la *toolbox* de MATLAB, sin embargo, en este caso se ha optado por una configuración manual donde se configuran además muchos otros aspectos no accesibles desde la *toolbox*.



# ÍNDICE DE FIGURAS

Figura 1. Diagrama genérico de bloques que intervienen en la generación de energía eléctrica a partir de un generador de corriente AC.....	5
Figura 2. Señales involucradas en la generación de las corrientes de salida.....	7
Figura 3. Generación de señales de control de los IGBT usando la técnica de PWM. ..	9
Figura 4. Inclusión de un Control Predictivo en el sistema de generación de energía basado en un convertidor de 3 niveles.....	11
Figura 5. Inclusión de un método de adaptabilidad en el Control Predictivo para un convertidor 3L-NPC. ....	20
Figura 6. Estructura genérica de una red neuronal artificial o ANN. ....	22
Figura 7. Circuito interno de un inversor trifásico de 3 niveles, 3L-NPC. ....	28
Figura 8. Esquema de funcionamiento simplificado de un inversor 3L-NPC.....	30
Figura 9. Secuencias correctas de activación y desactivación de los IGBT durante las transiciones de estados de la primera rama de un inversor 3L-NPC. ....	33
Figura 10. Representación en el plano $\alpha\beta$ de los vectores de tensión correspondientes a cada estado de conmutación de un inversor 3L-NPC en el plano $\alpha\beta$ . ....	36
Figura 11. Circuito y modelo de la carga a la salida del inversor. ....	37
Figura 12. Representación fasorial de la potencia aparente S como suma de la componente en fase o potencia activa P, y la componente reactiva Q. ....	42
Figura 13. Representación de la relación fasorial en el plano $\alpha\beta$ de las tensiones y corrientes de red.....	44
Figura 14. Ejemplo de relación entre las componentes $\alpha\beta$ de ejes estacionarios, y las componentes dq de ejes rotatorios para cierta relación entre fasores de corriente y tensión. ....	45
Figura 15. Elementos funcionales incluidos en el bloque de sincronización con la red o SRF-PLL y generación de corrientes de referencia.....	47
Figura 16. Esquema eléctrico del Bus-DC, puntos y valores de tensión para un convertidor 3L-NPC. ....	50
Figura 17. Ejemplos de desequilibrios del Bus-DC formado por los diferentes tipos de vectores o estados de conmutación: (a) Vector nulo $j=1$ (N,N,N), (b) Vector positivo $j=16$ (P,0,N), (c) Vector negativo $j=11$ (0,0,P).....	51
Figura 18. Matriz de transiciones entre pares de estados con el número de conmutaciones que se producen en un inversor 3L-NPC. ....	54

Figura 19. Diagrama de bloques general del Algoritmo de Control Predictivo sobre un inversor de 3 niveles auto-sincronizado con la fase de la red. ....	55
Figura 20. Ejemplo de conversión de tensiones trifásicas $e_{abc}$ a $e_{\alpha\beta}$ . ....	56
Figura 21. Señales principales implicadas en el bloque FSR-PLL y la generación de consignas en $\alpha\beta$ . ....	57
Figura 22. Ejemplo de relación entre la tensión $e_{\alpha}(k)$ y la corriente de referencia $i^*_{\alpha}(k)$ cuando hay una consigna $Q^*$ positiva y negativa. ....	58
Figura 23. Ejemplo de corrientes $i_{\alpha}(k+1)$ predichas tras aplicar el modelo predictivo para cada estado de conmutación $0 \leq j \leq 26$ en un inversor 3L-NPC para varios períodos de ejecución. ....	59
Figura 24. Variación del estado de conmutación óptimo al generar las corrientes. Relación entre tensión de salida del inversor $V_{A0}$ y la corriente $i_{\alpha}(t)$ generada junto a la tensión de red $e_{\alpha}(t)$ . ....	60
Figura 25. Circuito eléctrico real de la carga del convertidor 3L-NPC. ....	63
Figura 26. Efecto de una variación de $R$ en torno a un 20% de su nominal sobre el tracking de corrientes y la distorsión armónica total (THD). ....	65
Figura 27. Efecto de una variación de $R$ en torno a un 20% de su nominal sobre el desequilibrio del Bus-DC y la frecuencia de conmutación de los IGBT. ....	66
Figura 28. . Efecto de una variación de $L$ en torno a un 20% de su nominal sobre el tracking de corrientes y la distorsión armónica total (THD). ....	66
Figura 29. Efecto de una variación de $L$ en torno a un 20% de su nominal sobre el desequilibrio del Bus-DC y la frecuencia de conmutación de los IGBT. ....	67
Figura 30. Ejemplo de corriente $i_{\alpha}$ generada por el controlador MPC con un período de muestreo de $T_s=100\mu s$ (10kHz) y $T_s=10\mu s$ (100kHz). ....	69
Figura 31. Efecto sobre los índices de calidad debido a la variación del período de muestreo $T_s$ del sistema. ....	70
Figura 32. Efecto sobre los índices de calidad debido a la variación de la tensión $V_{DC}$ del Bus-DC. ....	73
Figura 33. Generación de corrientes con un inversor 3L-NPC con $V_{DC} = 540V$ y tensión máxima de red eléctrica 320V. ....	74
Figura 34. Distribución de las componentes eléctricas trifásicas para el caso normal de funcionamiento (a), corte de tensión en la fase $b$ (b) y un hueco de tipo A (c). ....	76
Figura 35. Respuesta del controlador MPC ante un hueco de tipo A en la red eléctrica de un 20% (0.8pu). ....	77
Figura 36. Respuesta del controlador MPC ante una caída de tensión de la fase $b$ . ....	78
Figura 37. Medición del tiempo de ejecución de un ciclo del algoritmo MPC. ....	81

Figura 38. Marcas de inicio de ejecución y fin de ejecución de un ciclo de control y actuación del controlador.....	82
Figura 39. . Respuesta dinámica del algoritmo MPC ante un cambio de consignas....	83
Figura 40. Respuesta del algoritmo MPC ante un cambio de consigna de $P^*$ desde 0 a 100kW analizando la corriente de referencia $i_q^*$ , y la generada $i_q$ . ....	84
Figura 41. Espectro de frecuencia en unidades naturales de la corriente $ia(k)$ generada por un inversor 3L-NPC con $f_s=10\text{kHz}$ y la configuración expuesta.....	86
Figura 42. Espectro de frecuencia en unidades de dB de la corriente $ia(k)$ generada por un inversor 3L-NPC con $f_s=10\text{kHz}$ y la configuración expuesta.....	87
Figura 43. Región ampliada de las principales distorsiones encontradas en frecuencia sobre la corriente $ia(k)$ , y muestra de la señal.....	88
Figura 44. Representación del desequilibrio del Bus-DC .....	95
Figura 45. Esquema funcional del bloque de medición de la frecuencia de conmutación media de los IGBT del sistema.....	97
Figura 46. Diagrama de bloques del Algoritmo de Control Predictivo Adaptativo propuesto, basado en el MPC. ....	98
Figura 47. Diferentes puntos de trabajo considerados en cuanto a las consignas de potencia ( $P^*, Q^*$ ). ....	101
Figura 48. Curvas de dependencia con $\lambda_{DC}$ de los índices de calidad para $P^*=100\text{kW}$ y $Q=0\text{kVAr}$ . ....	104
Figura 49. Detalle de variación del desequilibrio del Bus-DC para $\lambda_{DC} \geq 0.5$ .....	105
Figura 50. Curvas de dependencia con $\lambda_{SW}$ de los índices de calidad para $P^*=100\text{kW}$ y $Q=0\text{kVAr}$ . ....	106
Figura 51. Gráfica de superficie de la desviación de corriente en función de $\lambda_{DC}$ y $\lambda_{SW}$ . ....	108
Figura 52. Gráfica de superficie del THD en función de $\lambda_{DC}$ y $\lambda_{SW}$ . ....	109
Figura 53. Gráfica de superficie (recortada) del desequilibrio del bus-DC en función de $\lambda_{DC}$ y $\lambda_{SW}$ . ....	110
Figura 54. Gráfica de superficie de la frecuencia de conmutación en función de $\lambda_{DC}$ y $\lambda_{SW}$ . ....	111
Figura 55. Comparativa de curvas de dependencia con $\lambda_{DC}$ de los índices de calidad para los tres casos de configuración de potencia prefijados. ....	114
Figura 56. Comparativa de curvas de dependencia con $\lambda_{SW}$ de los índices de calidad para los tres casos de configuración de potencia prefijados. ....	116

Figura 57. Variación de los parámetros de configuración del algoritmo MPC para obtener el espacio de observaciones. ....	118
Figura 58. Esquema de actuación para encontrar el modelo de adaptabilidad del algoritmo de Control Predictivo.....	120
Figura 59. Ejemplos de regresión lineal unidimensional (a) y bidimensional (b). Mathworks ®.....	122
Figura 60. Muestra de resultados obtenidos mediante regresión lineal múltiple.....	123
Figura 61. Error cometido mediante la aproximación por regresión lineal múltiple. ....	124
Figura 62. Estructura de una red neuronal de propagación positiva de una capa oculta con 5 neuronas. ....	126
Figura 63. Resultados de la validación de la red neuronal de propagación hacia adelante con una capa oculta de 5 neuronas.....	127
Figura 64. Errores cometidos usando la red neuronal de propagación hacia adelante con una capa oculta de 5 neuronas.....	127
Figura 65. Evolución de la etapa de entrenamiento de la red neuronal de propagación hacia adelante con una capa oculta de 5 neuronas. ....	129
Figura 66. Histograma de errores cometidos durante el proceso de entrenamiento de la red neuronal de propagación hacia adelante con una capa oculta de 5 neuronas. ....	130
Figura 67. Estructura de una red neuronal recurrente de una capa oculta con 15 neuronas y una dependencia temporal de una muestra. ....	131
Figura 68. Resultados de la validación de una red neuronal recurrente de una capa oculta con 15 neuronas y una dependencia temporal de una muestra. ....	132
Figura 69. Errores cometidos usando la red neuronal recurrente de una capa oculta con 15 neuronas y una dependencia temporal de una muestra.....	132
Figura 70. Histograma de errores cometidos durante el proceso de entrenamiento de una red neuronal recurrente de una capa oculta con 15 neuronas y una dependencia temporal de una muestra.....	133
Figura 71. Evolución de la etapa de entrenamiento de la red neuronal recurrente de una capa oculta con 15 neuronas y una dependencia temporal de una muestra. ....	134
Figura 72. Ejemplo de dos funciones de pertenencia para el caso de clasificación de la potencia reactiva Q en lógica difusa.....	135
Figura 73. Diagrama de bloques del Algoritmo de Control Predictivo Adaptativo usando una red neuronal artificial para el ajuste de los pesos de la función de coste.....	139
Figura 74. Estructura básica de una FF-ANN Perceptrón Multicapa.....	140
Figura 75. Estructura de una neurona artificial y su equivalente biológico.....	141



Figura 76. Diseño genérico de la FF-ANN Perceptrón Multicapa para modelar el comportamiento del algoritmo A-MPC.....	148
Figura 77. Gráfica del error cuadrático medio cometido por la red neuronal en función del número de neuronas de la capa oculta, y el valor de la pendiente de regresión R. ....	151
Figura 78. Diseño final de la FF-ANN que se implementará en el algoritmo A-MPC.	152
Figura 79. Comparación del resultado con patrones de validación sobre una FF-ANN usando funciones de transferencia Tangente-Sigmoidal, o Lineal en la capa oculta de la red.....	153
Figura 80. Muestra de los 100 primeros resultados con patrones de validación aplicados a la FF-ANN diseñada. ....	157
Figura 81. Error medio cometido en las salidas de la red neuronal. ....	157
Figura 82. Estructura computacional de una neurona de la capa oculta para la estructura de red neuronal propuesta.....	162
Figura 83. Estructura computacional de una neurona de la capa de salida para la estructura de red neuronal propuesta.....	163
Figura 84. Función de transferencia tangente-sigmoidal.....	164
Figura 85. Error de cuantificación en la implementación de la función Tangente-sigmoidal mediante tablas de valores precalculados. ....	166
Figura 86. Modelo de implementación en Simulink de la función Tangente-sigmoidal. ....	167
Figura 87. Modelo de implementación en Simulink-HDL Coder de una neurona de la capa oculta. ....	168
Figura 88. Implementación en Simulink de una neurona de la capa de salida. ....	169
Figura 89. Implementación en Simulink-HDL Coder de la red FF-ANN completa.....	170
Figura 90. Muestra de una comparativa de resultados obtenidos tras aplicar patrones de validación a la FF-ANN desde MATLAB, y desde el modelo implementado con Simulink. ....	172
Figura 91. Convertidor 3L-NPC utilizado para la obtención de los resultados experimentales. ....	176
Figura 92. Tarjeta FPGA Xilinx ZC702 de desarrollo e interfaz de comunicaciones y muestreo del convertidor. ....	177
Figura 93. Tarjeta de interfaz de comunicaciones con el sistema de electrónica de potencia. ....	177
Figura 94. Plataforma experimental utilizada para realizar los experimentos. ....	178

Figura 95. Relación entre voltajes de red, referencias de corrientes y corrientes generadas en componentes alfa-beta cuando se le aplica al controlador una referencia de potencia activa $P = 100\text{kW}$ .	180
Figura 96 Relación entre voltajes de red, referencias de corrientes y corrientes generadas en componentes alfa-beta cuando se le aplica al controlador unas referencias de potencia activa $P = 80\text{kW}$ y reactiva $Q = 60\text{kVAr}$ .	181
Figura 97. Comparativa del desequilibrio del Bus-DC para el caso de que exista o no potencia reactiva $Q$ .	182
Figura 98. Respuesta del sistema A) de un convertidor con pesos fijos ante una variación de consignas de potencia $P=100\text{kW}$ y $Q=0\text{kVAr}$ , a $P=80\text{kW}$ y $Q=60\text{kVAr}$ .	184
Figura 99. Respuesta del sistema B) de un convertidor con ajuste de pesos dinámicos ante una variación de consignas de potencia $P=100\text{kW}$ y $Q=0\text{kVAr}$ , a $P=80\text{kW}$ y $Q=60\text{kVAr}$ .	185
Figura 100. Respuesta obtenida por el controlador sobre la corriente $i_a$ y desequilibrio del Bus-DC, con una función de coste estática tras aplicar un cambio de referencias de potencia $P^*=100\text{kW}$ y $Q^*=0\text{kVAr}$ , a $P^*=80\text{kW}$ y $Q^*=60\text{kVAr}$ .	186
Figura 101. Respuesta obtenida por el controlador sobre la corriente $i_a$ y desequilibrio del Bus-DC, con una función de coste dinámica tras aplicar un cambio de referencias de potencia $P=100\text{kW}$ y $Q=0\text{kVAr}$ , a $P=80\text{kW}$ y $Q=60\text{kVAr}$ .	187
Figura 102. Respuesta del sistema para el caso A) de un convertidor con pesos fijos ante una variación de consignas de potencia $P=100\text{kW}$ y $Q=0\text{kVAr}$ , a $P=60\text{kW}$ y $Q=0\text{kVAr}$ .	188
Figura 103. Respuesta del sistema para el caso B) de un convertidor con ajuste de pesos dinámicos ante una variación de consignas de potencia $P^*=100\text{kW}$ y $Q^*=0\text{kVAr}$ , a $P^*=60\text{kW}$ y $Q^*=0\text{kVAr}$ .	189
Figura 104. Respuesta continua del controlador A-MPC con ajuste de pesos dinámicos ante tres variaciones de consignas de potencia $P^*=100\text{kW}$ y $Q^*=0\text{kVAr}$ , $P^*=60\text{kW}$ y $Q^*=80\text{kVAr}$ y por último $P^*=100\text{kW}$ y $Q^*=0\text{kVAr}$ .	191
Figura 105. Respuesta continua sobre la corriente $i_a$ para los tres cambios de referencias de potencia planteados en el experimento.	192
Figura 106. Tensión de salida del convertidor, y corriente generada para la fase 'a' de la red eléctrica, para una referencia de frecuencia de conmutación de $1700\text{Hz}$ .	194
Figura 107. Tensión de salida del convertidor, y corriente generada para la fase 'a' de la red eléctrica, para una referencia de frecuencia de conmutación de $1600\text{Hz}$ .	195
Figura 108. Diferencias en la conmutación entre estados para el caso estudiado con $f_{sw}^*=1700\text{Hz}$ y $f_{sw}^*=1600\text{Hz}$ .	196

Figura 109. Corriente $i_a$ generada y desequilibrio del Bus-DC del controlador A-MPC con $\Delta V_c^*=15V$ .....	197
Figura 110. Corriente $i_a$ generada y desequilibrio del Bus-DC del controlador A-MPC con $\Delta V_c^*=10V$ .....	198
Figura 111. Corriente $i_a$ generada y desequilibrio del Bus-DC del controlador A-MPC con $\Delta V_c^*=5V$ .....	199
Figura 112. Interfaz de entrenamiento de la <i>toolbox Neural Network</i> de MATLAB. ....	208
Figura 113. Evolución del error cuadrático medio o MSE durante el proceso de entrenamiento.....	209

# ÍNDICE DE TABLAS

Tabla 1. Estados de conmutación de la primera rama de un inversor 3L-NPC.....	29
Tabla 2. Definición de los diferentes estados de conmutación de un inversor 3L-NPC en base a las señales de control de los IGBT. ....	30
Tabla 3. Secuencias de conmutación correctas de las señales de control de los IGBT para asegurar un buen funcionamiento, para el caso específico de la primera rama de un inversor 3L-NPC. ....	32
Tabla 4. Definición de los estados de conmutación en el plano $\alpha\beta$ de un inversor 3L-NPC. ....	34
Tabla 5. Diferentes corrientes $i_o$ generadas por los estados de conmutación en un inversor 3L-NPC. ....	52
Tabla 6. Número de conmutaciones en transiciones de estados de cada rama del inversor 3L-NPC. ....	54
Tabla 7. Efecto de la variación de $R = 3.63\text{m}\Omega$ hasta un $\pm 20\%$ , con $L = 2\text{mH}$ constante, sobre el funcionamiento del controlador.....	64
Tabla 8. Efecto de la variación de $L = 2\text{mH}$ hasta un $\pm 20\%$ , con $R = 3.63\text{m}\Omega$ constante, sobre el funcionamiento del controlador.....	64
Tabla 9. Efecto de la variación de $T_s$ sobre el funcionamiento del controlador MPC. .	69
Tabla 10. Efecto de la variación de $V_{DC}$ sobre el funcionamiento del controlador MPC. ....	72
Tabla 11. Valores de los diferentes puntos de configuración de potencia ( $P^*, Q^*$ ) considerados para obtener el espacio de observaciones.....	102
Tabla 12. Dependencia con $\lambda_{DC}$ de los índices de calidad para $P^*=100\text{kW}$ y $Q=0\text{kVAr}$ . ....	103
Tabla 13. Dependencia con $\lambda_{SW}$ de los índices de calidad para $P^*=100\text{kW}$ y $Q=0\text{kVAr}$ . ....	105
Tabla 14. Dependencia del desbalanceo de corriente $\Delta i_{\alpha\beta}$ respecto a los parámetros de peso $\lambda_{DC}$ y $\lambda_{SW}$ de la función de coste.....	107
Tabla 15. Dependencia de la distorsión armónica o THD respecto a los parámetros de peso $\lambda_{DC}$ y $\lambda_{SW}$ de la función de coste.....	109
Tabla 16. Dependencia del desequilibrio del bus-DC respecto a los parámetros de peso $\lambda_{DC}$ y $\lambda_{SW}$ de la función de coste.....	110

Tabla 17. Dependencia de la frecuencia de conmutación de los IGBT respecto a los parámetros de peso $\lambda_{DC}$ y $\lambda_{SW}$ de la función de coste. ....	111
Tabla 18. Dependencia con $\lambda_{DC}$ de los índices de calidad para $P^*=60kW$ y $Q=80kVar$ . ....	112
Tabla 19. Dependencia con $\lambda_{DC}$ de los índices de calidad para $P^*=43kW$ y $Q=90kVar$ . ....	113
Tabla 20. Dependencia con $\lambda_{SW}$ de los índices de calidad para $P^*=60kW$ y $Q=80kVar$ . ....	115
Tabla 21. Dependencia con $\lambda_{SW}$ de los índices de calidad para $P^*=43kW$ y $Q=90kVar$ . ....	115
Tabla 22. Coeficientes de regresión lineal encontrados para modelar el comportamiento del sistema.....	123
Tabla 23. Resultados obtenidos para las posibles soluciones de aproximación de la función de adaptabilidad.....	137
Tabla 24. Evolución del error cuadrático medio (MSE) y la pendiente de la recta de regresión (R) para diferente número de neuronas de la capa oculta. ....	150
Tabla 25. Factores multiplicativos o pesos de las neuronas de la capa oculta en la FF-ANN entrenada. ....	154
Tabla 26. Factores multiplicativos o pesos de las neuronas de la capa de salida en la FF-ANN entrenada. ....	155
Tabla 27. <i>Bías</i> de las neuronas de la capa oculta y la capa de salida en la red FF-ANN diseñada. ....	155
Tabla 28. Muestra de valores contenidos en las tablas incluidas para modelar la función no lineal Tangente-sigmoidal. ....	165
Tabla 29. Recursos consumidos en la implementación VHDL de la FF-ANN en la placa ZC702.....	173
Tabla 30. Análisis de tiempos realizados desde Simulink después de la generación de código VHDL de la FF-ANN.....	173
Tabla 31. Reportes de análisis temporales del bloque implementado de la FF-ANN desde el entorno de Vivado, sobre la placa de evaluación ZC702.....	174

# REFERENCIAS BIBLIOGRÁFICAS

1. *Recent Advances and Industrial Applications of Multilevel Converters*. **S. Kouro, M. Malinowski, K. Gopakumar, J. Pou, L.G. Franquelo, B. Wu, J. Rodriguez, M.A. Perez y J.I. León**. Agosto 2010, IEEE Transactions on Industrial Electronics, Vol. 57, pp. 2553-2580.
2. **Peña, Emilio Bueno**. *Optimización del Comportamiento de un Convertidor de Tres Niveles NPC Conectado a la Red Eléctrica*. s.l.: Departamento de Electrónica. Universidad de Alcalá, 2005. Trabajo de Tesis Doctoral.
3. *A Survey on Neutral-Point Clamp Inverters*. **J. Rodriguez, S. Bernet, P.K. Steimer y I.E. Lizama**. Julio 2010, IEEE Transactions on Industrial Electronics, Vol. 57, pp. 2219-2230.
4. **Celanovic, Nikola**. *Space Vector Modulation and Control of Multilevel Converters*. s.l.: Instituto Politécnico de Virginia, 2000.
5. *Predictive Control in Power Electronics and Drivers*. **P. Cortés, M.P. Kazmierkowski, R.M. Kennel, D.E. Quevedo y J. Rodriguez**. Diciembre 2008, IEEE Transactions on Industrial Electronics, Vol. 55, pp. 4312-4324.
6. *Space Vector Modulation for Three-Level NPC Converter With Neutral Point Voltage Balance and Switching Loss Reduction*. **Yang, J., Lee, F. C. and Lu, Sizhaou**. 10, Octubre 2014, IEEE Transaction on Power Electronics, Vol. 29, pp. 5579-5591. 1941-0107.
7. *Selective Harmonic Elimination in Three-Phase Multi-Module Voltage-Source Inverters*. **M. Narimani, G. Moschopoulos**. 2012. Applied Power Electronics Conference and Exposition (APEC'12), 27th Annual IEEE. pp. 1562-1567.
8. *Direct Power Control of PWM Converter without Power Source Voltage Sensors*. **Noguchi, T., et al., et al**. 3, 1998, IEEE Transaction on Industry Applications, Vol. 34, pp. 473-479.
9. *Three-level NPC voltage source converter based direct control power of double fed induction generator at low constant switching frequency*. 1, Marzo 2013, Revue des Energies Renouvelables, Vol. 16, pp. 91-103.

10. *Novel space vector based hysteresis current control (HCC) strategies for matrix converter.* **Wang, X. and Tseng, K. J.** 2015. European Conference on Power Electronics and Applications. 90-75815-09-3.
11. **Davoodnezhad, Reza.** *Hysteresis Current Regulation of Voltage Source Inverters with Constant Switching Frequency.* s.l. : RMIT University Australia, 2014.
12. **Holmes, D. Grahame and Lipo, Thomas A.** *Pulse Width Modulation for Power Converters: Principles and Practice.* s.l. : Wiley-IEEE Press, 2003. 978-0-471-20814-3.
13. *Grid interfacing of distributed energy sources by three-level BtB NPC converter under distorted grid voltage.* **Jasinski, M, et al., et al.** Octubre 2011, Predictive Control of Electrical Drives and Power Electronics (PRECEDE), pp. 30-35. 978-1-4577-1914-1.
14. *Model Predictive Control for Electrical Drivers.* **A. Linder, R. Kennel.** 2005. IEEE 36th Power Electronics Specialist Conference (PESC'05). pp. 1793-1799.
15. *Model Predictive Control. A Simple and Powerful Method to Control Power Converters.* **S. Kouro, P. Cortes, R. Vargas, U. Ammann, J. Rodriguez.** Junio 2009, IEEE Transactions on Industrial Electronics, Vol. 56, pp. 1826-1838.
16. **Rodríguez, J. and Cortés, P.** *Predictive Control of Power Converters and Electrical Drives.* s.l. : IEEE Wiley, 2012. 978-1-119-96398-1.
17. *Weight factor selection for model-based predictive control of a four-level flying-capacitor inverter.* **Thielemans, S., Vyncke, T. J. and Melkebeek, J.** 3, 2012, IET Power Electronics, Vol. 5, pp. 323-333.
18. *Model Predictive Control: A review of its applications in power electronics.* **Vazquez, S., et al., et al.** 1, Marzo 2014, IEEE Industrial Electromagnetics, Vol. 8, pp. 16-31.
19. *Model Predictive Control for Power Converters and Drives: Advances and Trends.* **Vazquez, S., et al., et al.** Noviembre 2016, IEEE Transaction on Industrial Electronics, Vol. 99, pp. 1-1.
20. *Generalized predictive current control (gpcc) for grid-ie three phase inverters.* **Judewicz, M. G., et al., et al.** 7, Julio 2016, IEEE Transaction on Industrial Electronics, Vol. 63, pp. 4475-4484.

21. *Explicit model-predictive control of a pwm inverter with an lcl filter.* **Mariethoz, S. and Morari, M.** 2, IEEE Transactions on Industrial Electronics, Vol. 56, pp. 389-399.
22. *State of the Art of Finite Control Set Model Predictive Control in Power Electronics.* **J. Rodriguez, M. P. Kazmierkowski, J. R. Espinoza, P. Zanchetta, H. Abu-Rub, H. A. Young, C.A. Rojas.** 2, Mayo 2013, IEEE Transactions on Industrial Informatics, Vol. 9, pp. 1003-1016.
23. *FPGA-Based Implementation of a Predictive Current Controller for Power Converters.* **Martín Sánchez, Pedro, et al., et al.** 3, s.l. : IEEE, Diciembre 2012, IEEE Transactions on Industrial Informatics, Vol. 9, pp. 1312-1321. ISSN 1551-3203.
24. *Predictive Current Control of Voltage Source Inverter.* **J. Rodriguez, J. Pontt, C.A. Silva, P. Correa, P. Lezana, P. Cortés, U. Ammann.** Febrero 2007, IEEE Transactions on Industrial Electronics, Vol. 54, pp. 495-503.
25. *Generalized Predictive Control (GPC). Ready for Use in Drive Applications?* **R. Kennel, A. Linder, M. Linke.** 2001. IEEE 32nd Power Electronics Specialists Conference (PESC'01). pp. 1839-1844.
26. *Cost Function-based Predictive Control for Power Converters.* **Cortés, P., et al., et al.** 2006, IEEE IECON 06, pp. 2268-2273.
27. *Model Predictive Control Based Selective Harmonic Mitigation Technique for Multilevel Cascade H-Bridge Converters.* **Aggrawal, H., et al., et al.** 2011. 37th Annual Conference on IEEE Industrial Electronics Society. pp. 4424-4432.
28. *Predictive Control of a Three-Phase Neutral-Point-Clamped Inverter.* **Vargas, R, et al., et al.** 5, Octubre 2007, IEEE Transactions on Industrial Electronics, Vol. 54, pp. 2697-2705.
29. *Heuristic Multi-Objective Optimization for Cost Function Weights Selection in Finite Sate Model Predictive Control.* **Zanchetta, P.** Munich : s.n., 2011. IEEE Workshop PRECEDE 2011. pp. 70-75.
30. *Guidelines for Weighting Factors Design in Model Predictive Control of Power Converters and Drives.* **P. Cortes, S. Kouro, B. La Roca, R. Vargas, J. Rodriguez, J.I. León, S. Vazquez, L.G. Franquelo.** 2009. IEEE International Conference on Industrial Technology (ICIT 2009). pp. 1-7.



31. *A single-objective predictive control method for a multivariable single-phase three-level npc converter-based active power filter.* **Acuña, P., et al., et al.** 7, Julio 2015, IEEE Transactions on Industrial Electronics, Vol. 62, pp. 4598-4607.
32. *Multiobjective Switching Stateselector for Finite-States Model Predictive Control Based on Fuzzy Decision making in a Matrix Converter.* **Villaroel, F., et al., et al.** 2, 2013, IEEE Transaction on Industrial Electronics, Vol. 60, pp. 589-599.
33. *Predictive Torque and Fluxcontrol without Weighting Factors.* **Rojas, C.A., et al., et al.** 2, 2013, IEEE Transaction on Industrial Electronics, Vol. 60, pp. 681-690.
34. *Predictive Control of a Back-to-Back NPC Converter-Based Wind Power System.* **Calle-Prado, A., et al., et al.** 7, Julio 2016, IEEE Transactions on Industrial Electronics, Vol. 63, pp. 4615-4627.
35. *An Improved FCS-MPC Algorithm for an Induction Motor with an Imposed Optimized Weighting Factor.* **S. Davari, D. Khaburi, R. Kennel.** 3, 2012, IEEE Transactions on Power Electronics, Vol. 27, pp. 1540-1551.
36. *Model Predictive Control of Grid-Tied Four-Level Diode-Clamped Inverters for High Power Wind Energy Conversion System.* **V. Taramasu, B. Wu, J. Chen.** 6, 2014, IEEE Transactions on Power Electronics, Vol. 29, pp. 2861-2873.
37. *Model Predictive Control of an Asymmetric Flying Capacitor Converter.* **P. Lezama, R. Aguilera, D.E. Quevedo.** Junio 2009, IEEE Transactions on Industrial Electronics, Vol. 56, pp. 1839-1846.
38. *Design of a Back-toBack NPC Converter Interface for Wind Turbines with Squirrel-cage Induction Generator.* **Bueno, E. J., et al., et al.** 3, 2008, IEEE Transactions on Energy Conversion, Vol. 23, pp. 932-945.
39. *Predictive Current Control of Voltage-Source Inverters.* **H. Abu-Rub, J. Guzinski, Z. Krzeminski, H.A. Toliyat.** Junio 2004, IEEE Transactions on Industrial Electronics, Vol. 51, pp. 585-593.
40. *A Discrete-Timne Predictive Current Control for PMSM.* **H.T. Moon, H.S. Kim, M.J. Youn.** Enero 2003, IEEE Transactions on Power Electronics, Vol. 18, pp. 464-472.

41. *Delay Compensation in Model Predictive Current Control of a Three-phase Inverter*. **Cortés, P., et al., et al.** 2, 2012, IEEE Transaction on Industrial Electronics, Vol. 59, pp. 1323-1325.
42. **Machado Llerena, Osmell.** *Implementación en FPGA de un Algoritmo de Control Predictivo en Convertidores Multinivel*. s.l. : Escuela Politécnica Superior. Universidad de Alcalá., 2011. Tesis de Fin de Máster.
43. *FPGA-Based Predictive Current Controller for Synchronous Machine Speed Drive*. **M. W. Naouar, A.A. Naassani, E. Monmasson, I. Slama-Belkhodja.** Julio 2008, IEEE Transactions on Power Electronics, Vol. 23, pp. 2115-2126.
44. *Design Space Exploration for the Implementation of a Predictive Current Controller based on FPGA*. **Martín, Pedro, et al., et al.** Delf. Holanda. : s.n., 2012, 23rd IEEE Conference on Application-Specific System, Architectures and Processors (ASAP).
45. *FPGA-based approach for the parallelization of a Predictive Current Controller Algorithm*. **Machado, O., et al., et al.** Valencia : s.n., 2014, ELECTRIMACS 2014, pp. 664-669. 978-84-616-9961-2.
46. **Machado Llerena, Osmell.** *Optimización y Diseño de Hardware Especificado en Xilinx System Generator*. Madrid : Departamento de Electrónica. Universidad de Alcalá, 2011.
47. **De Micheli, Giovanni.** *Synthesis and Optimization of Digital Circuits*. s.l. : McGraw-Hill International Editions, 1994.
48. *Predictive control based selective harmonic elimination with low switching frequency for multilevel converters*. **Kouro, Samir, et al., et al.** Noviembre 2009, Energy Conversion Congress and Exposition ECCE 2009. 2329-3748.
49. **Rojo, J. M.** *Regresión Lineal Múltiple*. Madrid : Instituto de Economía y Geografía, 2007, 3.
50. **R. Kizys, A.A. Juan.** *Modelo de Regresión Lineal Múltiple*. s.l. : Proyecto e-Math. Universidad Oberta de Catalunya.
51. **Doran, H.** *Applied Regression Analysis in Econometrics*. s.l. : Marcel Dekker, 1989.
52. **Rojas, R.** *Neural Network. A Systematic Introduction*. Berlin : Springer-Verlag, 1996.

53. **M.T. Hagan, H.B. Demuth, M. Beale.** *Neural Network Design.* s.l. : Thomson, 1996. 7-111-10841-8/TP-2583.
54. *Neural Network Implementation Using FPGA: Issues and Application.* **A. Muthuramalingam, S. Himavathi, E. Srinivasan.** 2008. International Journal of Information and Communication Engineering. pp. 396-402.
55. *Red Neuronal Implementada en FPGA.* **G. Tejada, S.J. Zarzosa, V.H. Benitez.** [ed.] Universidad Nacional Mayor de San Marcos. Lima : s.n., Diciembre 2008, Electrónica - UNMS.
56. *Fuzzy Predictive Control of Nonlinear System.* **W. Dhouib, M. Djemel, M. Chtourou.** 2011. 8th International Multi-Conference on Systems, Signals & Devices.
57. *Fuzzy Logic Control of Predictive Current Control for Grid-Connected Single Phase Inverter.* **S. Premrudeepreechacharn, T. Poapornsawan.** 2000. Photovoltaic Specialist Conference, 2000. Conference Record of the 28th IEEE. pp. 1715-1718.
58. *Application of Indirect Adaptive Model Predictive Control Supervised by Fuzzy Logic to a Diesel Generator.* **J. Mamboundou, N. Langlosi.** Santiago de Chile : s.n., 2011. 9th IEEE International Conference on Control and Automation (ICCA). pp. 1037-1043.
59. **CT-Concept Technologie AG, AN-0901.** *Methodology for Controlling Multi-Level Converter Topologies with SCALETM-2 IGBT Drivers.*
60. **Volke, Andreas and Hornkamp, Michael.** *IGBT Modules. Technologies, Driver and Application.* s.l. : Infineon. 978-3-00-040134-3.
61. *Discrete-time current control of voltage-fed three-phase PWM inverters.* **Kukrer, O.** 2, Marzo 1996, IEEE Transactions on Power Electronics, Vol. 11, pp. 260-269. 1941-0107.
62. *Implementación de Sistemas Empotrados Aplicados a Algoritmos de Control y Sincronización para Convertidores Electrónicos de Potencia Conectados a la Red Eléctrica.* **Sáez Dorado, Vanessa.** s.l. : Universidad de Alcalá, 2010. Tesis de Fin de Máster.

63. **Pesquer, Luis Guasch.** *Efectos de los huecos de tensión en las máquinas de inducción y en los transformadores trifásicos.* s.l. : Tesis Doctoral. Universidad Politécnica de Cataluña., 2006.
64. **Mathworks.** Statistics and Machine Learning Toolbox. [Online] <http://es.mathworks.com/help/stats/index.html>.
65. **H. Demuth, M. Beale.** *Neural Network Toolbox.* s.l. : The MathWorks, 2013.
66. *Approximation capabilities of multilayer feedforward networks.* **Hornik, Kurt.** 2, Viena : Elsevier, 1991, Neural Networks, Vol. 4, pp. 251-257.
67. *Levenberg-Marquardt algorithm with adaptive momentum for the efficient training of feedforward networks.* **Amapazis, N and Perantonis, S. J.** Julio 2000, IEEE-INNS-ENNS International Joint Conference on Neural Networks.
68. *Outline of a new approach to the analysis of complex.* **Zadeh, L.A.** Febrero 2010, IEEE Transaction on System Man and Cybernetics Society, pp. 28-44. 2168-2909.
69. *Reducing the Dimensionality of Data with Neural Networks.* **Hinton, G.E. and Salakhutdinov, R.R.** 5786, Julio 2006, Science, Vol. 313, pp. 504-507. DOI: 10.1126/science.1127647.
70. *Levenberg-Marquardt algorithm with adaptive momentum for the efficient training of feedforward networks.* **Amapazis, N and Perantonis, S.J.** Julio 2000, IEEE-INNS-ENNS International Joint Conference on Neural Networks.
71. *Preprocessing for image classification by convolutional neural networks.* **Kumar Pal, Kuntal and Sudeep, K.S.** 2016. 978-1-5090-0774-5.
72. **Heaton, Jeff.** *Introduction to Neural Networks for Java.* s.l. : Heaton Research. 1604390085.
73. **Xilinx.** 7 Series DSP48E1 Slice. User Guide (UG479). [www.xilinx.com/support](http://www.xilinx.com/support). [Online] 2016.
74. **Mathworks.** Xilinx FPGAs and Zynq SoCs. [Online] <http://es.mathworks.com/solutions/fpga-design/simulink-with-xilinx-system-generator-for-dsp.html>.

75. **Xilinx**. System Generator for DSP. [Online] <https://www.xilinx.com/products/design-tools/vivado/integration/sysgen.html>.
76. **MathWorks**. *HDL Coder. User's Guide*. [MATLAB R2016a] 2012-2016.
77. Xilinx Zynq-7000 All Programmable SoC Product Advantages. [Online] 2015. <http://www.xilinx.com/products/silicon-devices/soc/zynq-7000.html>.
78. Xilinx Zynq-7000 SoC ZC702 Evaluation Kit. [Online] 2015. <http://www.xilinx.com/products/boards-and-kits/ek-z7-zc702-g.html>.
79. *Predictive Control of a Three-Phase Neutral-Point-Clamped Inverter*. **R. Vargas, P. Cortes, U. Ammann, J. Rodriguez, J. Pontt**. Octubre 2007, IEEE Transactions on Industrial Electronics, Vol. 54, pp. 2697-2705. 5.
80. *Design of back-to-back NPC Converter Interface for Wind Turbines with Squirrel-Cage Induction Generator*. **Bueno, Emilio J., et al., et al.** 2008, IEEE Transaction on Energy Conversion, Vol. 23, pp. 932-945.